

JULIANA FONSECA ANTUNES

**Previsão de Carga Multinodal Usando a Rede Neural
ART-ARTMAP *Fuzzy***

JULIANA FONSECA ANTUNES

**Previsão de Carga Multinodal Usando a Rede Neural
ART-ARTMAP *Fuzzy***

Tese apresentada à Faculdade de Engenharia
do Campus de Ilha Solteira - UNESP, como
parte dos requisitos para obtenção do título de
Doutor em Engenharia Elétrica.

Área de conhecimento: Automação.

Prof. DR. CARLOS ROBERTO MINUSSI
Orientador

Ilha Solteira
2013

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

A636p Antunes, Juliana Fonseca.
Previsão de carga multinodal usando a rede neural ART-ARTMAP fuzzy /
Juliana Fonseca Antunes. -- Ilha Solteira: [s.n.], 2013
110 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2013

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Redes neurais artificiais. 2. Teoria da ressonância adaptativa. 3. Previsão
de cargas multinodal. 4. Previsão de cargas a curto prazo.

CERTIFICADO DE APROVAÇÃO

TÍTULO: Previsão de Carga Multinodal Usando a Rede Neural ART-ARTMAP-Fuzzy

AUTORA: JULIANA FONSECA ANTUNES

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovada como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARA LÚCIA MARTINS LOPES

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. FABIO ROBERTO CHAVARETTE

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. EDMARCIO ANTONIO BELATI

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC


Prof. Dr. JUAN GUILLERMO LAZO LAZO

Departamento de Engenharia Elétrica / Pontífica Universidade Católica do Rio de Janeiro

Data da realização: 12 de julho de 2013.

Dedico essa tese ao grande amor da minha vida, meu esposo Rothschild, aos meus filhos Júlia, Natália e Anderson, aos meus pais, Mananiel e Lêda, e a minha sogra, Cacilda, pelo apoio incondicional.

AGRADECIMENTOS

A Deus, por ter me mantido no meu caminho, demonstrando minha fé e perseverança em finalizar mais essa jornada, que me deu forças nos momentos difíceis, não foram poucos, mas agradeço por acalmar meu coração nesses momentos.

A meu marido Rothschild, pela força incondicional, por me encorajar e estimular sempre para chegar até esse momento final. Suportou todo meu mau humor e nervosismo. Por cuidar de nossas filhas com todo carinho e amor que só um pai pode ter por um filho.

À minha pequena filhinha Júlia. Não foi fácil para ela essa distância, as viagens, mas ela foi forte e maravilhosa. E a minha filhona Natália por ajudar o pai e a irmã, pelo carinho e cuidado sempre. Ficar longe deles foi o maior desafio que já pude enfrentar, pois família é tudo de bom que temos nessa vida.

Ao meu orientador, professor Dr. Carlos Roberto Minussi pela paciência, ensinamentos e compreensão na minha orientação. À Profa. Dra. Anna pelas conversas que sempre transmitiam muita tranquilidade.

A meus pais e minha sogra pelo cuidado, atenção e carinho as minhas filhas e ao meu marido na minha ausência nesses meses de estudo.

Agradeço a minha vó Victoria que no auge dos seus 102 anos é exemplo de vida, carinho e muito amor. Em memória da minha vó Nova por toda sua simplicidade e carinho.

Aos amigos e colegas da UNESP e IFMT pela ajuda e incentivo nos estudos das disciplinas.

Aos amigos Nelcileo, Mário e Lucas pela companhia, ideias e conversas durante essa fase de estudos longe de casa.

À CAPES pelo apoio financeiro durante o afastamento para pesquisa, desenvolvimento e escrita da tese.

Aos técnicos do laboratório do Departamento de Engenharia Elétrica pelo suporte, aos funcionários da Seção de Pós Graduação pela atenção que sempre me atenderam, em especial Márcia.

Aos membros da banca examinadora pela colaboração e sugestões para versão final da tese.

RESUMO

Previsão de cargas é uma atividade indispensável para o funcionamento dos sistemas de energia elétrica e contribuem para o planejamento e a operação, visando garantir o fornecimento de energia aos consumidores de forma segura, confiável e econômica. A previsão a curto prazo ajuda a estimar o fluxo de carga, tomar decisões de prevenção de sobrecargas, entre outras ações que são rotineiramente executadas. Para realizar a previsão é necessário identificar os padrões do comportamento de consumo e da sua relação com as variáveis externas do ambiente no sistema. A maioria dos estudos de previsões de cargas é realizada utilizando métodos estatísticos, onde é necessário modelar a carga matematicamente. Apesar de fornecerem bons resultados utilizam métodos complexos é de difícil modelagem. As técnicas de inteligência artificial proporcionam uma nova ferramenta, capazes de modelar uma grande quantidade de dados de cargas e construir a relação entre as variáveis do sistema de forma automática. Dentre essas técnicas inteligentes destacam-se as redes neurais e a lógica fuzzy que são utilizadas para previsão de cargas. Nesta pesquisa, apresenta-se um método de previsão multinodal (em vários pontos de interesse da rede elétrica) de carga elétrica, de curto prazo, utilizando uma rede neural artificial baseada na arquitetura ART (Adaptive Resonance Theory), denominada de rede neural ART-ARTMAP Fuzzy. As redes neurais ART apresentam características fundamentais, a estabilidade e a plasticidade, para treinar e prever de forma rápida e confiável. O método proposto foi implementado na plataforma MATLAB, onde foi possível realizar a previsão de cargas, por exemplo, de um sistema composto por nove subestações. Como forma de avaliar os resultados obtidos pela previsão, foi calculada o erro percentual máximo da previsão e o erro percentual médio. Para realizar o treinamento e a previsão de cargas são utilizados os dados históricos cedidos pela Comissão de Energia Elétrica da Nova Zelândia, no qual os dados foram usados aplicando o procedimento do método de movimento de uma janela. O sistema proposto produziu resultados com precisão similar a métodos disponíveis na literatura com tempo de previsão semelhante ao da previsão global e sem restrição ao tamanho da base de dados.

Palavras chave: Redes neurais artificiais. Teoria da ressonância adaptativa. Previsão de cargas multinodal. Previsão de cargas a curto prazo.

ABSTRACT

Load forecasting is an essential activity for the operation of electric power systems and contribute to the planning and operation in order to ensure the supply of electricity to consumers in a secure, reliable and economical way. The short-term forecasting aids estimating the load flow, makes decisions to prevent overloads, among other actions that are routinely performed. It is necessary to identify the consumer behavior patterns and the relationship with the external environment variables of the system to perform the forecasting. The estimated load is determined via the following predictors. Many studies of load forecasting use statistical methods, where it is necessary to mathematically model the load. While providing good results in using complex methods it is difficult to model. The artificial intelligence techniques provided a new tool capable of modeling a large amount of data loads and build the relationship between the variables of the system. Among these intelligent techniques there are the neural networks and fuzzy logic which are used to load forecasting. This research presents a method for short-term multinodal electrical load forecasting (at various points of main interest), using an artificial neural network architecture based on ART (Adaptive Resonance Theory) neural network called ART-ARTMAP Fuzzy. ART neural networks have fundamental characteristics, stability and plasticity, to train and provide fast and reliable results. The method was implemented in Matlab platform where it was possible to perform the prediction, for example, for a system composed of nine substations. In order to evaluate the results obtained by the predictions the maximum percentage error of the forecast and the average percentage error were calculated. Historical load data yielded by the Electricity Commission of New Zealand are used to execute the training and load forecasting. The proposed system accurately produced results similar to methods available in the literature considering as for example, the prediction time and not considering the overall size of the database.

Keywords: Artificial neural networks. Adaptive resonance theory. Multinodal load forecasting. Short term load forecasting.

LISTA DE FIGURAS

Figura 1	– Problematização.	16
Figura 2	– Arquitetura da rede neural ART.....	29
Figura 3	– Fluxograma do algoritmo de classificação da rede neural ART Fuzzy.....	32
Figura 4	– Arquitetura da rede ARTMAP Fuzzy.....	33
Figura 5	– Fluxograma da rede neural ARTMAP Fuzzy.....	36
Figura 6	– Sistema predictor de carga multinodal.	38
Figura 7	– Definição das entradas/saída da rede neural artificial.....	41
Figura 8	– Previsão de carga via deslocamento da janela.	42
Figura 9	– Deslocamento das janelas.	43
Figura 10	– Esquema de funcionamento do treinamento e previsão das redes neurais.....	45
Figura 11	– Funcionamento do método condicional implementado.	46
Figura 12	– Modelo PSO-GLF.....	48
Figura 13	– Modelo PSO-GLF.....	49
Figura 14	– Previsão global 08/01/2008.....	52
Figura 15	– Erro percentual da previsão global.....	52
Figura 16	– Previsão subestação 01 – 08/01/2009.	53
Figura 17	– Erro Percentual Subestação 01 – 08/01/2009.	53
Figura 18	– Previsão Subestação 02 – 08/01/2009.....	54
Figura 19	– Erro Percentual Subestação 02 – 08/01/2009.	54
Figura 20	– Previsão subestação 03 – 08/01/2009.	55
Figura 21	– Erro Percentual Subestação 03 – 08/01/2009.	55
Figura 22	– Previsão subestação 04 – 08/01/2009.	56
Figura 23	– Erro Percentual Subestação 04 – 08/01/2009.	56
Figura 24	– Previsão subestação 05 – 08/01/2009.	57
Figura 25	– Erro Percentual Subestação 05 – 08/01/2009.	57
Figura 26	– Previsão subestação 06 – 08/01/2009.	58
Figura 27	– Erro Percentual Subestação 06 – 08/01/2009.	58
Figura 28	– Previsão subestação 07 – 08/01/2009.	59
Figura 29	– Erro Percentual Subestação 07 – 08/01/2009.	59
Figura 30	– Previsão subestação 08 – 08/01/2009.	60
Figura 31	– Erro Percentual Subestação 08 – 08/01/2009.	60
Figura 32	– Previsão subestação 09 – 08/01/2009.	61

Figura 33 – Erro Percentual Subestação 09 – 08/01/2009.	61
Figura 34 – Comparação de MAPES para os três tipos de deslocamento de janela.	62
Figura 35 – Previsão de carga via deslocamento da janela	67
Figura 36 – Neurônio biológico	81
Figura 37 – Neurônio artificial	82
Figura 38 – Treinamento supervisionado	84
Figura 39 – Treinamento não-supervisionado	84
Figura 40 – Rede neural não-recorrente	85
Figura 41 – Treinamento não-supervisionado	86
Figura 42 – Conjuntos nebulosos	88
Figura 43 – Operador AND	88
Figura 44 – Operador OR	89
Figura 45 – Operador NOT	89
Figura 46 – Sistema de Controle Fuzzy	89
Figura 47 – Localização geográfica das subestações	91
Figura 48 – Diagrama elétrico	92
Figura 49 - Comportamento da carga global 2007 e 2008	95
Figura 50 - Curva de carga média de cada dia da semana (2007 e 2008)	96
Figura 51 - Curva média de cada dia da semana pertencente e não pertencente ao horário de verão	96
Figura 52 - Curvas de cargas dos dias da semana dos anos de 2007 e 2008	97
Figura 53 - Análise espectral das curvas de carga dos anos de 2007 e 2008	98
Figura 54 - Correlação das cargas das amostras n com a amostras n-1, n-2, n-3 e n-4.....	99

LISTA DE TABELAS

Tabela 1 – Parâmetros utilizados pela rede neural ART-ARTMAP Fuzzy.....	49
Tabela 2 – MAPEs e erro máximo previsão global e local.	51
Tabela 3 – Comparativo Mapes GRNN-MR e ART ARTMAP Fuzzy.	63
Tabela 4 – Especificações dos transformadores de cada subestação.....	92

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	: AutoRegressive Integrated Moving Average
ADALINE	: ADaptive LINear Element
ART	: Adaptive Resonance Theory (Teoria da Ressonância Adaptativa)
CDS	: Centralized Dataset
CL	: Carga Local
CG	: Carga Global
E _{max}	: Erro Percentual Máximo da Previsão Diária
FPCG	: Fator de Participação da Carga Global
F ₀	: Camada do Neurônio que Representa o Vetor de Entradas
F ₁	: Camada do Neurônio de Comparação
F ₂	: Camada do Neurônio de Reconhecimento
ρ	: Parâmetro de Vigilância
α	: Parâmetro de Escolha
β	: Taxa de Treinamento
T _j	: Função Escolha
M	: Número de Vetores de Entrada na Camada F ₁
N	: Dimensão dos Vetores de Entrada que Formam Categorias em F ₂
A	: Padrão de Entrada Para Rede ART-ARTMAP Fuzzy
B	: Padrão de Saída da Rede ART-ARTMAP Fuzzy
W	: Vetor de Pesos
\wedge	: Operador Fuzzy AND
J	: Índice da Categoria Ativa Escolhida Para o Módulo ART _a
K	: Índice da Categoria Ativa Escolhida Para o Módulo ART _b
ε	: Tolerância de Erro

LTM : Long Term Memory (Memória a Longo Prazo)

MAPE : Mean Absolute Percentage Error (Erro percentual absoluto médio)

PCG : Sistema Previsor de Carga Global

PCL : Sistema Previsor de Carga Local

PFPCG : Sistema Previsor do Fator de Participação da Carga Global

PSO : Particle Swarm Optimization

RNA : Rede Neural Artificial

SEE : Sistemas de Energia Elétrica

SEP : Sistema Elétrico de Potência

STLF : Short Term Load Forecasting (Previsão de Carga a Curto Prazo)

STM : Short Term Memory (Memória a curto prazo).

SUMÁRIO

1	INTRODUÇÃO	13
1.1	PROBLEMA	15
1.2	OBJETIVO DO TRABALHO	17
1.3	CONTRIBUIÇÕES DO TRABALHO	17
1.4	ORGANIZAÇÃO DO TRABALHO	17
2	REVISÃO BIBLIOGRÁFICA	19
2.1	INTRODUÇÃO	19
2.2	ANÁLISE DAS PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS	19
3	PREVISÃO DE CARGA	22
3.1	INTRODUÇÃO	22
3.2	FATORES QUE INFLUENCIAM O COMPORTAMENTO DA CARGA	23
3.3	MÉTODOS PARA PREVISÃO DE CARGA	24
3.4	CLASSIFICAÇÃO DA PREVISÃO DE CARGA	25
3.5	TIPOS DE PREVISÃO	25
4	TEORIA DA RESSONÂNCIA ADAPTATIVA	27
4.1	INTRODUÇÃO	27
4.2	TEORIA DA RESSONÂNCIA ADAPTATIVA	27
4.3	REDE NEURAL ART	29
4.4	REDE NEURAL ARTMAP <i>Fuzzy</i>	32
5	METODOLOGIA PARA PREVISÃO DE CARGA	37
5.1	INTRODUÇÃO	37
5.2	BASE DE DADOS	37
5.3	SISTEMA PREVISOR	38
6	SIMULAÇÕES E RESULTADOS	44
6.1	INTRODUÇÃO	44
6.2	SIMULAÇÃO	44
6.3	PARTICLE SWARM OPTIMIZATION	46
6.4	RESULTADOS	50
7	CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS	64
7.1	CONCLUSÕES	64
7.2	SUGESTÕES PARA TRABALHOS FUTUROS	66
	REFERÊNCIAS	68
	APÊNDICE A	79
	APÊNDICE B	80
	APÊNDICE C	87
	APÊNDICE D	91
	APÊNDICE E	93

1 INTRODUÇÃO

A previsão de carga é uma exigência básica nos processos de planejamento e de operação de Sistemas Elétricos de Potência (SEP).

A crescente importância está relacionada ao mercado de energia exigir melhores valores de eficiência energética e, também, pelo estabelecimento de novas normas de preservação do meio ambiente que introduziu difíceis restrições para o gerenciamento e controle do sistema de energia.

O estudo de previsão de carga proporciona um conjunto de informações vitais para que os sistemas de energia elétrica possam ser planejados e controlados de forma segura e confiável, fornecendo energia elétrica de boa qualidade.

A previsão de cargas elétricas pode ser feita a curto, médio e longo prazo. Curto prazo (Short Term Load Forecasting, STLF) prevê de meia em meia hora, ou ainda picos de carga diários; médio prazo prevê de algumas semanas até um ano; e longo prazo prevê demanda de um período que pode variar de alguns anos a algumas décadas. Previsão de cargas a curto prazo também pode ser definida como previsão por hora da demanda de eletricidade para um tempo de espera que vai de um dia a até sete dias de antecedência (TOPALLI; ERKMEN; TOPALLI, 2006).

Por conseguinte, a previsão de carga (O'DONOVAN, 1983), em sistemas elétricos de potência, constitui-se numa atividade importante, tendo em vista que a maioria dos estudos realizados (fluxo de potência, despacho econômico, planejamento da expansão, análise de estabilidade, entre outras rotinas) somente poderá ser realizada se houver a disponibilidade de uma estimativa da carga a ser atendida. Estes estudos visam proporcionar, aos engenheiros, um conjunto de informações vitais para que os sistemas elétricos possam ser planejados e operados de forma segura, confiável e econômica.

A estimativa da carga, seja de curto, médio ou de longo prazo, é determinada, via procedimentos previsores, a partir de dados históricos do consumo de energia, dados climáticos (CHAABENE, 2008), entre outros fatores importantes. Esta previsão deve ser a mais precisa possível.

A maioria das previsões é realizada por procedimentos bastantes conhecidos na literatura especializada, e.g., técnica de regressão linear simples ou múltipla, alisamento

exponencial, estimação de estado, filtro de Kalman, ARIMA (AutoRegressive Integrated Moving Average) de Box & Jenkins (BOX; JENKINS; REINSEL, 2008). Estes métodos exigem que seja feita uma modelagem prévia da carga para aplicação posterior. Bons resultados têm sido obtidos apesar de, às vezes, serem requeridos grandes esforços computacionais, além de técnicas de modelagem complexas. Novas abordagens, baseadas na inteligência artificial (BENDER, 1996), têm sido abordadas na literatura especializada como metodologias alternativas, principalmente, por produzir resultados em que a modelagem da carga é estabelecida por processo de treinamento. Neste caso, a extração do conhecimento é realizada a partir de bases de dados. Neste grupo de técnicas inteligentes, podem-se destacar as RNA (Redes Neurais Artificiais) (HAYKIN, 2008). Ressalta-se que, na literatura, há uma grande quantidade de propostas usando redes neurais para previsão de carga (BASSI; OLIVARES, 2006; BUNN, 2000; CANCELO; ESPASA; GRAFE, 2008; CARPINTEIRO; REIS; SILVA, 2004; CHANDRASHEKARA; ANANTHAPADMANABHA; KULKARNI, 1999; CHEN; TZENG; HWANG, 1996; GONZALEZ-ROMERA; JARAMILLO-MORAN; CARMONA-FERNANDEZ, 2008; HONG, 2009; KERMANSHAHI; IWAMIYA, 2002; NAHI, 2006), lógica fuzzy (CHANDRASHEKARA; ANANTHAPADMANABHA; KULKARNI, 1999; DONG; PEDRYCZ, 2008; MIRANDA; MONTEIRO, 1999), conjuntos rústicos (rough sets) (XIAO et al., 2009) e outras técnicas (transformada wavelet, particle swarm), autômatos celulares (WOLFRAM, 2003; HONG, 2009; MIRANDA; MONTEIRO, 1999; NIU et al., 2009; ULAGAMMAI et al., 2007; WANG; HATZIARGYRIOU; TSOUKALAS, 2002), etc.

A previsão de carga, via de regra, é realizada de forma global (O'DONOVAN, 1983), ou seja, não discriminando a distribuição da carga entre os consumidores e o tipo da carga instalada, bem como a ser instalada. Esta forma de abordagem pode ser útil em algumas aplicações. Contudo, o mesmo não se observa com relação à operação, tendo em vista a necessidade de um melhor detalhamento e distribuição da carga (WU; YUAN; ZHU, 2003)

A grande dificuldade de prever a distribuição da carga como ela efetivamente acontece, certamente, passa pela necessidade de dispor de dados em grande quantidade, elaboração de modelos complexos e de técnicas que possam processar tais dados e produzir resultados precisos, confiáveis e rápidos.

Alguns resultados de previsão de cargas foram obtidos, neste sentido, na pesquisa (LOPES, 2005; LOPES; MINUSSI; LOTUFO, 2005) usando uma arquitetura neural ART descendente (CARPENTER; GROSSBERG; REYNOLDS, 1991; CARPENTER;

GROSSBERG; ROSEN, 1991) para o caso da previsão global. Na referida pesquisa foram obtidos resultados satisfatórios. Este módulo previsional produziu soluções com precisão compatível com os melhores resultados divulgados na literatura especializada e rapidez bastante superior, principalmente, se comparada à tradicional rede neural feedforward com treinamento realizado usando o algoritmo retropropagação (WERBOS, 1974). Ressalta-se que, comparando-se estas duas redes, a rede neural ART-ARTMAP Fuzzy é centenas de vezes mais rápidas, considerando-se os casos em que houve convergência. Isto acontece porque com a rede neural com retropropagação nem sempre se consegue convergência, principalmente em problemas com grande conjunto e diversidade de dados.

Evidentemente, várias propostas têm sido apresentadas na literatura para previsão de carga em ambiente de sistemas de distribuição (previsão multinodal) (HUANG; CHEN; LIN, 2005; LEFEBVRE; DESBIENS, 2002; MOTA; MOTA, 2005; NAHI, 2006; SANO; TEZUCA; FUKUDA, 2004; WANG et al., 2008) usando redes neurais (ALTRAN, 2010; CHANDRASHEKARA; ANANTHAPADMANABHA; KULKARNI, 1999; CHEN; TZENG; HWANG, 1996; NOSE-FILHO; LOTUFO; MINUSSI, 2011a; NOSE-FILHO; LOTUFO; MINUSSI, 2011b), lógica fuzzy (MIRANDA; MONTEIRO, 1999), previsão espacial (WILLIS, 2002), previsão espacial via autômatos celulares (MIRANDA; MONTEIRO, 1999), entre outras técnicas.

1.1 PROBLEMA

Um sistema de transmissão é composto principalmente pela linha de transmissão, transformadores e dispositivos de controle. Estes componentes podem ser matematicamente modelados com sistema gráfico de fluxo (aplicação da teoria de grafo), no qual os arcos representam a linha de transmissão e transformadores e os nós, chamados de barramentos, representam o ponto de conexão desses componentes. Os consumidores da energia elétrica estão conectados nesses barramentos. A soma de todos os consumidores desse barramento é a demanda de carga que deve ser fornecida. A companhia de energia deve assegurar que o atendimento das cargas seja feito com segurança. Essa análise no sistema depende da carga no barramento (SALGADO; OHISHI; BALLINI, 2011).

Cada barramento possui diversos transformadores e ligados a esses estão o consumidor, que possuem padrões de consumo distinto. Ressalta-se que a a previsibilidade vai diminuindo quando se aproxima de cada carga individual (consumidor), conforme é

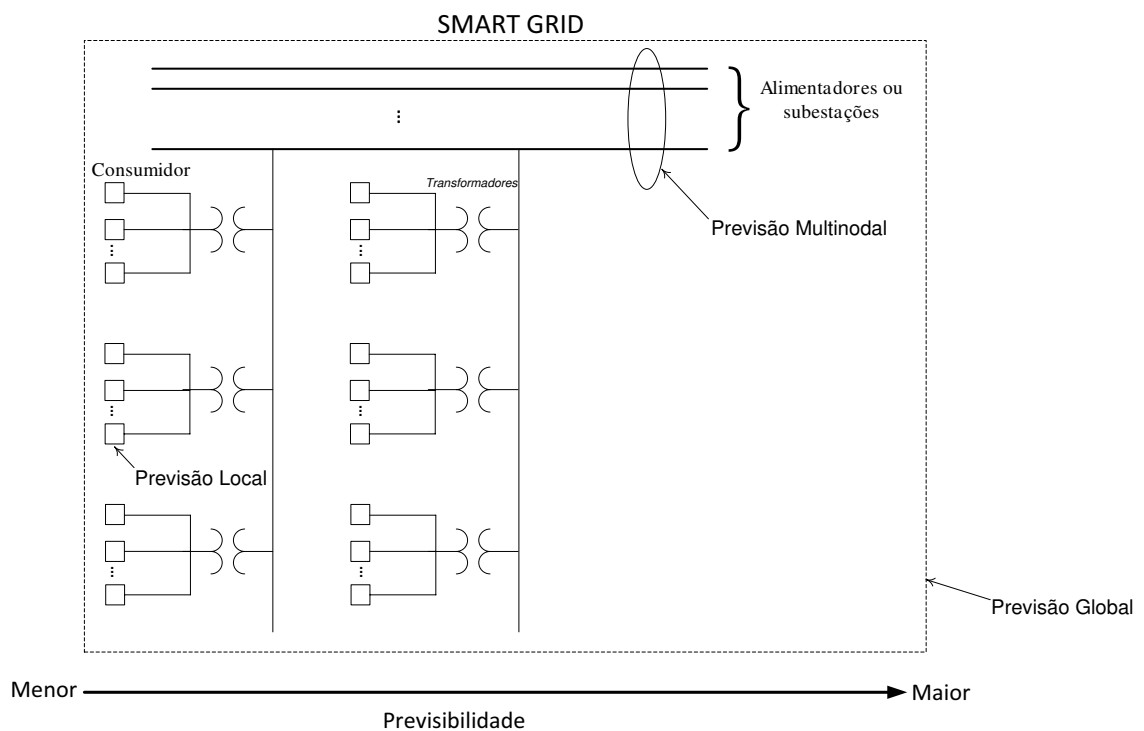
ilustrado na Figura 1. Além do padrão de consumo é necessário analisar fatores que podem influenciar o comportamento da carga.

Esses fatores fazem com que seja difícil de prever os níveis de demanda do sistema, principalmente os padrões de uso estimado de carga individual. No entanto, a totalidade dos resultados individuais das cargas em padrão de consumo distintos pode ser estatisticamente previsto (GROSS; GALIANA, 1987).

A previsão global tem sido bastante abordada em diversos artigos. A previsão multinodal possui poucos estudos e artigos científicos na área e a carga individual/consumidor ainda é uma área que não foi abordada em estudos e pesquisas de previsão de carga.

A composição da carga é a soma de todas as cargas individuais de todos os nós do sistema de potência. É possível determinar o padrão do sistema de carga se cada padrão de consumo individual for conhecido. Contudo, a demanda ou os padrões de uso de carga individuais (dispositivos) ou consumidores é aleatório e até não é muito utilizado. Existem diversos padrões que dependem das aplicações típicas de consumo. Esses fatores tornam impossível prever níveis do sistema de demanda. Felizmente, contudo, a totalidade das cargas individuais resulta em um padrão de consumo distinto que pode ser previsto (GROSS; GALIANA, 1987).

Figura 1 – Problematização.



Fonte: do próprio autor.

1.2 OBJETIVO DO TRABALHO

O objetivo deste trabalho é desenvolver um sistema inteligente para previsão de carga multinodal de curto prazo utilizando uma rede neural baseada na arquitetura ART (Adaptive Resonance Theory) (CARPENTER; GROSSBERG; ROSEN, 1991), denominada rede neural ART-ARTMAP Fuzzy.

A vantagem da utilização desta rede neural se deve ao fato dela apresentar característica de estabilidade (garantia de agrupar todos os elementos nos padrões criados pelo sistema) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória anteriormente adquirida), que são fundamentais para o processamento da rede.

Estes dois atributos proporcionam à rede neural a aprendizagem estável e convergência rápida. Deste modo, trata-se de uma rede neural com capacidade de sempre gerar uma solução, de forma rápida, e, também, dotada de recursos que possibilitam a inclusão do treinamento continuado, ou seja, as respostas, a princípio, podem ser melhoradas ao longo do tempo. Evidentemente sem custo computacional adicional, tendo em vista não haver necessidade de recomeçar o treinamento toda vez que existir padrões novos a serem inseridos na matriz de pesos da rede neural.

1.3 CONTRIBUIÇÕES DO TRABALHO

O uso da rede neural ART para realizar previsão de cargas multimodais, a curto prazo, é a principal contribuição desse trabalho, pois atualmente existem poucas pesquisas que realizam esse tipo de previsão e, principalmente, utilizando essa rede neural.

A rede foi desenvolvida em Matlab (não existe toolbox para essa rede), aplicando a metodologia de previsão de carga a curto prazo baseada nas redes neurais (ART-ARTMAP Fuzzy) para aplicações em que se faz necessária a obtenção de resultados multinodais com tempo de processamento satisfatório, disponibilizando um sistema previsor eficiente, em termos de precisão, confiabilidade e rapidez na obtenção de soluções.

1.4 ORGANIZAÇÃO DO TRABALHO

Após as considerações iniciais, é descrito a seguir, de forma breve como o trabalho está organizado.

Apresenta-se, no Capítulo 2, uma revisão bibliográfica sobre os modelos já desenvolvidos sobre previsão de cargas multinodal, com respectivas características e particularidades.

No Capítulo 3 são abordados os conceitos de previsão de cargas elétricas, descrevendo as características das cargas, fatores que influenciam a modelagem da carga, classificação dos tipos de carga.

No Capítulo 4 aborda-se a Teoria da Ressonância Adaptativa, apresentando os principais conceitos e arquitetura das redes neurais utilizada nesse trabalho.

No Capítulo 5 é apresentada a metodologia do sistema de previsão de cargas desenvolvida neste trabalho para resolver o problema de previsão de cargas multinodal.

O Capítulo 6 contém os resultados da aplicação e as comparações entre as simulações de previsão de cargas.

No Capítulo 7 são apresentadas as conclusões e contribuições desta pesquisa e também são colocadas sugestões para trabalhos futuros.

No Apêndice A, são relacionados os artigos publicados durante a fase de pesquisa e desenvolvimento da tese.

No Apêndice B são abordados os conceitos de Redes Neurais artificiais, descrevendo as características principais, aprendizado/treinamento e classificação.

No Apêndice C são apresentados os conceitos principais de Lógica Fuzzy.

Na Apêndice D, são apresentadas informações da região e dos transformadores utilizada nas subestações (Sistema Elétrico da Nova Zelândia). Esta base de dados foi gentilmente fornecida, ao Grupo de Pesquisa (Departamento de Engenharia Elétrica da UNESP de Ilha Solteira), para uso em pesquisa, pela Electricity Commission da Nova Zelândia (2010).

Finalmente, no Apêndice E é apresentada a modelagem dos dados feita por Nose-Filho (2010) e que foram utilizadas nesse trabalho.

2 REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

Planejamento da expansão, fluxo de potência, operação econômica, análise de segurança e controle de sistemas de energia elétrica são alguns exemplos de rotinas que dependem efetivamente do conhecimento do perfil da carga (O'DONOVAN, 1983). Trata-se de um problema de estimação dessas informações futuras de carga baseadas em valores passados, produzindo uma série temporal.

Vários métodos de previsão de cargas têm sido estudados na literatura. Alguns métodos precisam modelar a carga previamente para posteriormente aplicá-la, dentre eles pode-se citar: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado (GROSS; GALIANA, 1987), filtro de Kalman, métodos ARIMA de Box & Jenkins (BOX; JENKINS; REINSEL, 2008), entre outros.

A previsão de carga a curto prazo utilizando diferentes redes neurais artificiais tem sido foco de várias pesquisas apresentadas a seguir. Importante destacar que existem poucas pesquisas sobre previsão de carga multinodal utilizando a rede neural ART.

2.2 ANÁLISE DAS PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS

Existem diversos artigos que realizam a previsão de cargas a curto prazo, através de redes neurais artificiais. Neste contexto, serão apresentados, a seguir, alguns desses artigos, no qual é destacada a estratégia adotada, arquitetura e topologia da rede e os resultados obtidos.

Em Kiartzis et al. (1996) foi proposto a previsão de carga horária de um Sistema de Energia Elétrica (SEE) da ilha de Creta (Grécia) do ano de 1995. O treinamento de uma RNA do tipo MLP (Multilayer Perceptron) com dados referentes aos anos de 1990 a 1994, com topologia da rede em três camadas (cada camada com 64, 48 e 24 neurônios). Os dados de entrada referem-se à temperatura, dia da semana, dia do ano e cargas horárias de dois dias anteriores, que totalizam 64 entradas. A saída refere-se à carga horária, ou seja, 24 cargas horárias do dia seguinte. Foi feito o pré-processamento dos dados de treinamento, através da comparação das curvas de cargas previstas com curvas de cargas típicas, corrigindo possíveis irregularidades. O MAPE (Mean Absolute Percentage Error) anual foi de 2,52%.

No artigo de Fidalgo e Lopes (2005) foi proposta a previsão de carga horária utilizando RNAs do tipo MLP. As cargas são referentes aos valores de potência ativa, reativa

e de corrente elétrica de sistemas de distribuição de energia elétrica. São adotadas duas metodologias diferentes, a primeira utiliza a saída dada pela carga da hora seguinte e a outra que fornece os valores das 24 cargas do dia seguinte. A primeira metodologia utiliza RNA com três camadas, sendo 10 neurônios na camada de entrada, 7 na intermediária e 1 neurônio na camada de saída. O segundo método também utiliza três camadas, sendo que na primeira camada (entrada) tem 74 neurônios, 6 na intermediária e 24 na camada de saída. MAD (Mean Absolute Deviation) encontrado foi de 0,072 a 0,141 para uma previsão de 24 horas.

Na referência Altran (2010) foi proposta uma rede neural artificial do tipo perceptron multicamadas com treinamento baseado no algoritmo de retropropagação com a modificação da função de ativação da rede, onde foi substituída a função sigmoide por funções de base radial (ORR, 1996), a metodologia foi aplicada para previsão de carga a curto prazo global e multinodal baseada no conceito de fatores de participação da carga global. O MAPE alcançado foi de 1,43 para previsão global e na previsão local de 2,93.

Em Nose-Filho et al. (2009) é proposta a previsão de cargas horárias de um SEE brasileiro do ano de 1998 utilizando diferentes arquiteturas de RNAs. Uma dessas arquiteturas é a MLP treinada pelos algoritmos gradiente descendente com retropropagação e o algoritmo de Levenberg-Marquardt, ANFIS (Adaptive Neuro-Fuzzy Inference System) e GRNN (General Regression Neural Network / Rede Neural de Regressão Generalizada). As entradas são os indicadores de hora e dia da semana e as cargas passadas, e as saídas são as cargas previstas da hora seguinte. Os MAPEs diários obtidos variam de 0,97% a 2,31%.

Nos artigos de Nose-Filho, Lotufo, Minussi (2011a, 2011b) foi empregado um modelo similar ao proposto em Altran (2010) para a previsão multinodal do Sistema Elétrico da Nova Zelândia, foi utilizada a rede neural GRNN, como entrada da rede foi usado o mês, dia da semana, feriado, horário de verão e a carga média, mínima e máxima, os MAPEs diários encontrados para as nove subestações analisadas variam de 2,18% a 7,75%.

No artigo de Salgado, Ohishi e Ballini (2011) é realizada a previsão de carga em vários barramentos (multinodal) de SEE brasileiro, através da RNA do tipo MLP. São duas estratégias empregadas. A primeira realiza a previsão das cargas dos barramentos de forma individual e outra agrupa os barramentos semelhantes em clusters de carga. As entradas modeladas são obtidas através de uma análise de correlação entre a carga a ser prevista e os valores de cargas passadas. Os MAPEs diários variam de 1,87% a 7,32%, sendo que o modelo de cargas agrupadas realiza a previsão mais rápida (14 vezes) que a previsão individual.

O sistema de previsão de cargas proposto nesta pesquisa é constituído por um módulo de Previsão Global e outro Módulo de Previsão Multinodal, em que cada módulo possui sua própria RNA ART-ARTMAP Fuzzy, os módulos atuam juntos, primeiramente fazendo a previsão global e em seguida realizando as previsões locais. Outro ponto importante refere-se a grande rapidez na obtenção de soluções, a utilização da lógica fuzzy juntamente com a rede permite que sejam utilizadas na rede ARTMAP entradas binárias como analógicas.

Os trabalhos relacionados nessa seção evidenciam que não há muitas pesquisas no contexto de previsão multinodal e, principalmente, com aplicação da rede neural ART para realizar previsões de cargas elétricas. Alguns desses trabalhos foram importantes fontes de pesquisa, pois contribuíram para escolha da rede neural ART e para o modelo proposto para entrada de dados dessa rede, inclusive utiliza a mesma base de dados de Nose-Filho, Lotufo, Minussi (2011a) e o fator de participação de carga global de Altran (2010).

3 PREVISÃO DE CARGA

3.1 INTRODUÇÃO

O sistema de distribuição possui relevância indispensável no contexto de um sistema elétrico, não só pelo alto investimento, mas pelo elevado compromisso na qualidade de serviço prestado ao consumidor.

Para garantir essa qualidade de serviço é necessário o planejamento, que tem como objetivo adaptar o sistema elétrico e o sistema de suporte de distribuição às futuras demandas do mercado consumidor, com isso garantir o suprimento de energia a níveis compatíveis desse mercado e ao menor custo possível.

Existem dois tipos de planejamento:

- Nível estratégico: decidir sobre a escolha dos objetivos atuais de distribuição e sobre mudanças desses objetivos;
- Nível tático: processo de escolha dos recursos para se atingir os objetivos propostos.

Para alcançar objetivos e atender as necessidades do planejamento, é necessário conhecer a distribuição de carga, ano a ano, por áreas elementares (setores, regiões e etc.), de forma a possibilitar o dimensionamento de alimentadores e subestações.

A carga do sistema é a soma de todas as demandas individuais de todos os nós do sistema de energia. A princípio, pode-se determinar o padrão de carga do sistema se cada padrão de consumo é conhecido. Contudo, o padrão de uso de uma carga individual ou consumidor é aleatório e difícil de prever.

Uma tarefa importante do processo de planejamento é a previsão de carga. Além das técnicas disponíveis, deve-se utilizar da experiência e de conhecimento local. As cargas elétricas são compostas por diversos aparelhos e dispositivos que apresentam tendências que podem ser estatisticamente previstas, quando colocadas em conjunto.

3.2 FATORES QUE INFLUENCIAM O COMPORTAMENTO DA CARGA

As tendências são influenciadas por fatores que interferem na forma de modelar a carga e o seu comportamento no sistema. O comportamento do sistema pode ser influenciado por diversos fatores, sendo classificados em quatro grandes categorias (GROSS; GALIANA, 1987):

Fatores econômicos : ambiente econômico tem um efeito nos padrões de consumo de energia elétrica, tais como área demográfica (rural, residencial, industrial), crescimento de atividade industrial, mudanças no setor agropecuário e tendências econômicas, impactam significativamente sobre a tendência do declínio e crescimento do sistema de carga.

Fatores de tempo : comportamentos cíclicos e efeitos sazonais, três principais fatores de tempo desempenham um papel importante na influência nos padrões de carga, são eles:

Efeitos sazonais : consumo varia em forma cíclica ao longo do ano, em diferentes estações do ano.

Ciclo diário-semanal : é a consequência do padrão do dia de descanso de uma área de população, por exemplo, dias de sábado e domingo.

Feriados : feriados religiosos e oficiais (dias atípicos) tem efeito de reduzir os níveis de valores da carga.

Fatores climáticos : condições meteorológicas são responsáveis por variações significativas nos padrões de carga. Tem-se como exemplos: chuva e neve, temperatura, velocidade do vento, temporal com relâmpago e trovão, neblina, umidade relativa do ar, etc.

Fatores aleatórios : eventos que causam variações nos padrões de carga e que não podem ser explicados pelos outros fatores anteriormente expostos; refletem o fato do sistema de energia ser composto por um largo número de diversas cargas individuais. Um exemplo desse fator são as greves generalizadas e desligamento de instalações industriais.

3.3 MÉTODOS PARA PREVISÃO DE CARGA

Apesar de terem ocorrido diversos avanços na área de previsão, não é possível determinar qual é o melhor método para prever uma série temporal. Antecipar decisões de quanto uma usina deve gerar é importante, e essas decisões são resultados de uma previsão de carga a ser atendida.

Na literatura têm sido propostos diversos métodos de realizar previsão, estabelecendo com certo grau de precisão, esses métodos necessitam de duas condições fundamentais (TANG; ALMEIDA; FISCHWICH, 1991):

1. informações sobre o passado quantificadas em formato de dados e
2. admitir que o comportamento ocorrido no passado, de certa forma, irá se repetir no futuro.

Existem duas classes utilizadas para previsão de carga (O'DONOVAN, 1983), sendo elas:

- a) **Método intuitivo** : métodos que utilizam conhecimento de um especialista para descrever o comportamento da carga (O'DONOVAN, 1983).
- b) **Método Autônomo** : compreendem métodos que utilizam modelos baseados somente na extrapolação de observações passadas da carga, analisando a evolução da carga no tempo de acordo com determinados padrões de comportamento (O'DONOVAN, 1983), dessa forma podendo ser classificadas em:
 - a. horizontal : os dados da carga flutuam em torno de um determinado valor médio constante no tempo (O'DONOVAN, 1983).
 - b. sazonal : a carga é influenciada por fatores temporais, tais como, estações do ano, dias da semana (O'DONOVAN, 1983).
 - c. tendenciosa : os dados variam em torno de uma curva de tendência (média variável do tempo) (O'DONOVAN, 1983).

3.4 CLASSIFICAÇÃO DA PREVISÃO DE CARGA

Para prever uma carga temporal é necessário determinar os procedimentos que serão efetuados para geração e consumo da carga. Esta pode ser modelada em minutos, horas, dias, meses ou anos.

Pode-se classificar a previsão de carga de acordo com o período em que a carga é prevista. Existem quatro tipos de previsão de cargas, são elas (AL-KANDARI; SOLIMAN; EL-HAWARY, 2004; METAXIOTIS et al., 2003; MURTO, 1998; SWARUP; SATISH, 2002; YALCINOZ; EMINOGLU, 2005):

- Previsão de carga a longo prazo** : envolve período de 10 a 20 anos. Tem a finalidade de efetuar um planejamento a longo prazo. Não é considera dados de carga elétrica diária ou semanal.
- Previsão de carga a médio prazo** : envolve período de poucas semanas ou até mesmo alguns anos;
- Previsão de carga a curto prazo** : feita no intervalo de tempo de meia hora a poucas horas, ou até mesmo de 1 dia a 1 semana.
- Previsão de carga a curtíssimo prazo** : feita em poucos segundos, em menos de 15 minutos.

3.5 TIPOS DE PREVISÃO

Previsão de cargas elétricas desempenha um papel central na operação e planejamento da energia elétrica. A estimativa de energia em todo o país, o planejamento, a rotina de manutenção e programação de geração de energia elétrica diária são todos dependentes de uma boa previsão de cargas futuras (BAO, 2002).

Por causa dos diferentes tipos de previsão, o problema da previsão de carga pode ser representado em dois tipos:

- Previsão espacial** : prever distribuição de cargas futuras em uma região específica, como uma cidade, um estado ou um país.
- Previsão temporal** : prever cargas futuras em horas, dias, meses ou até anos para um fornecedor específico ou conjunto de consumidores.

A previsão temporal foi aplicada nesse trabalho, onde foi previsto cargas futuras a curto prazo, ou seja, de 30 em 30 minutos, ao longo de um sistema de transmissão e de distribuição da Nova Zelândia, onde existem pontos de interligação entre diferentes linhas, transformadores e consumidores, denominados barramentos (multinodal). Alguns barramentos associados à geração, interligação e também ao suprimento dos consumidores. Cada barramento atende um conjunto de consumidores (conforme apêndice D), sendo possível elaborar histórico de demanda de carga e estudar o perfil da demanda.

A previsão de carga multinodal, consiste na previsão das cargas em vários pontos de um sistema de energia elétrica, denominadas cargas locais. A previsão destas cargas pode ser realizada, independentemente, através de vários sistemas ou conjunta; a vantagem de se realizar esta previsão conjunta é o tempo gasto. Acredita-se que se pode realizar esta previsão com um tempo que pode ser comparado com o tempo gasto para a previsão da carga global.

4 TEORIA DA RESSONÂNCIA ADAPTATIVA

4.1 INTRODUÇÃO

A Teoria da Ressonância Adaptativa, proposta por Grossberg (1976a e 1976b), foi desenvolvida a partir da teoria do processo de informação cognitiva humana, envolvendo a visão, a fala, o desenvolvimento cortical e as iterações cognitivo-emocionais.

Essa teoria é motivada e baseada em três princípios biológicos, os quais são destacados pelas seguintes características (SILVA; SPATTI; FLAUZINO, 2010):

- Normalização de sinais : capacidade dos sistemas biológicos em se adaptar a ambientes que se alteram em todo momento;
- Intensificação de contraste : potencialidade de identificar detalhes sutis a partir de sucessivas observações realizadas sobre o ambiente;
- Memória de curto prazo : possibilidade de armazenar, momentaneamente, as informações sensoriais advindas do mecanismo de intensificação de contraste, antes que possam ser decodificadas visando à tomada de decisões.

A importância desta rede está baseada na resolução do dilema da plasticidade e da estabilidade (características fundamentais da família das redes ART), processo feito através do teste de vigilância, que torna a rede mais rápida e precisa (CARPENTER; GROSSBERG, 1992).

A estabilidade garante o agrupamento de todos os elementos nas categorias geradas pelo sistema (armazenamento do conhecimento adquirido pela rede), através do processo de adaptação dos pesos, que tendem ao valor mínimo entre a entrada da rede e o peso a ser atualizado, fazendo que o ajuste de pesos seja realizado e os novos valores tendem a diminuir até estabilizarem (LOPES, 2005).

4.2 TEORIA DA RESSONÂNCIA ADAPTATIVA

A Teoria da Ressonância Adaptativa surgiu do resultado da tentativa de compreender como sistemas biológicos são capazes de continuar apreender, sem comprometer a estabilidade de padrões previamente aprendidos (CARPENTER; GROSSBERG, 1992). Simula o processo de aprendizagem do cérebro humano, explica a forma como nosso cérebro

processa e categoriza informações recebidas na medida em que são apresentadas novas informações.

As redes ART são redes neurais desenvolvidas para codificar reconhecimento estáveis, em tempo real, através da auto-organização, em resposta as sequências arbitrárias de padrões de entrada (CARPENTER; GROSSBERG, 1992).

Essa rede é importante, pois resolve o dilema da estabilidade-plasticidade, que é a capacidade de aprender novas informações sem que as informações passadas sejam perdidas, através da ativação de novas categorias, e isto tem que ser feito de forma a não afetar na estabilidade do sistema.

As topologias baseadas na arquitetura ART podem ser divididas em cinco grupos principais que são classificadas, em função do tipo de suas entradas e seus processos de treinamento, dentre elas pode se destacar:

- Rede neural **ART1** : possui a capacidade de reconhecer padrões de entrada binários e possui treinamento não-supervisionado. (CARPENTER; GROSSBERG, 1987a);
- Rede neural **ART2** : também possui treinamento não-supervisionado. Emprega os padrões com entradas binárias ou analógicas (CARPENTER; GROSSBERG, 1987b);
- Rede neural **ART-Fuzzy** : rede baseada no treinamento não-supervisionado e que engloba em sua arquitetura cálculos baseados na lógica fuzzy (CARPENTER; GROSSBERG; ROSEN, 1991).
- Rede neural **ARTMAP** : rede que possui treinamento supervisionado. É composta por dois módulos ART interconectados, através do campo inter-ART. Esta rede também pode identificar padrões de entradas binários ou analógicos (CARPENTER; GROSSBERG; REYNOLDS, 1991).
- Rede neural **ARTMAP Fuzzy** : esta rede possui treinamento supervisionado como a rede neural ARTMAP, porém, todos os cálculos são fundamentados na lógica fuzzy (CARPENTER; GROSSBERG, 1992).

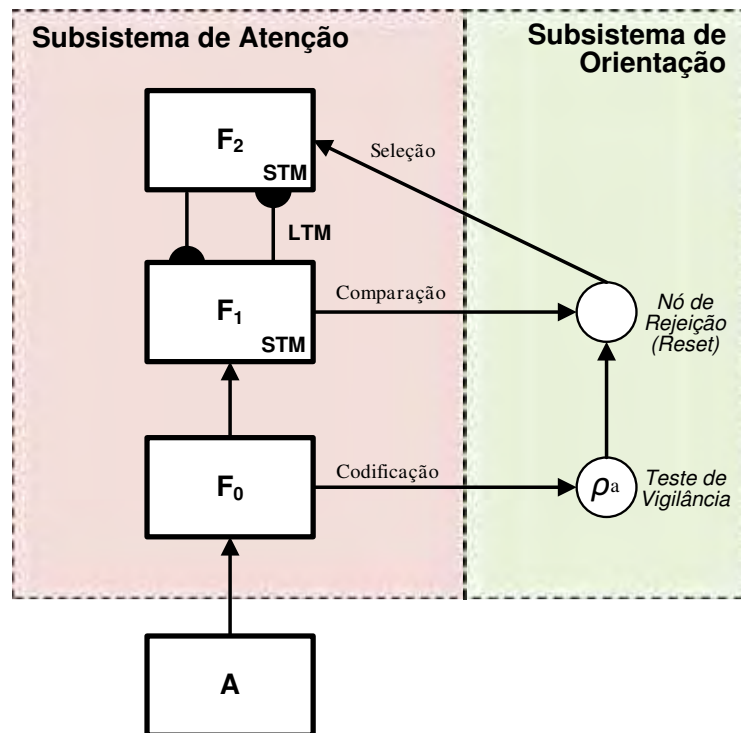
4.3 REDE NEURAL ART

O processo de treinamento das redes da família ART é um processo de treinamento em tempo real para ambientes não-estacionários, onde os pesos são ajustados a cada apresentação de padrões de entrada, atualizando os pesos dinamicamente sem precisar treinar padrões aprendidos anteriormente. As redes da família ART não correm o risco de desestabilizar a saída para padrões de entrada já aprendidos (CARPENTER; GROSSBERG, 1987a).

ART é um sistema que auto-organiza padrões de entrada em categorias de reconhecimento, comparando o padrão de entrada atual com uma representação de categoria selecionada.

A arquitetura da rede neural ART pode ser descrita por dois subsistemas principais: o subsistema de atenção e o subsistema de orientação (CARPENTER; GROSSBERG, 1987a), mostrados na Figura 2.

Figura 2 – Arquitetura da rede neural ART.



Fonte: Lopes (2005).

O subsistema de atenção é composto por duas camadas de neurônios, denominadas F_1 (responsável pela comparação) e F_2 (reconhecimento de padrões) e pela camada de nós que representa o vetor de entrada atual A (F_0). Os neurônios (F_1 e F_2) são interconectados por pesos (conexões diretas, F_1 a F_2 , e recorrentes, F_2 a F_1), denominadas memórias de longo

prazo (LTM – Long Term Memory); os padrões de atividades produzidos por esses neurônios são denominados memória de curto prazo (Short-Term Memory – STM). A aprendizagem ocorre durante a ressonância (CARPENTER; GROSSBERG, 1992).

O subsistema de orientação é utilizado para estabilizar a aprendizagem do sistema, permitindo que a rede aprenda novas entradas sem esquecer seu conhecimento prévio. Esse subsistema é responsável por dizer se houve ou não ressonância, através do parâmetro denominado vigilância, ρ (ρ possui valor decimal compreendido entre 0 e 1), que determina se um padrão de entrada pode ser representado em uma das categorias existentes.

A rede ART armazena informações em forma de categorias. O número de neurônios na camada F_1 e F_2 são iguais ao número máximo de categorias que o sistema é capaz de armazenar. Para cada categoria, existe um vetor peso associado a ela. Uma categoria é dita ativa quando o vetor peso associado a ela armazena informações de padrões já apresentados à rede. Uma categoria é dita inativa se possuir, a ela atribuída, um vetor peso inalterado. As categorias inativas correspondem à memória “em branco” da rede neural.

A diferença entre os dois subsistemas é que um indica a categoria vencedora (subsistema de atenção), já o outro subsistema tem a tarefa de aceitar a categoria proposta (subsistema de orientação) ou reorientar a busca para a escolha de uma nova categoria.

Alguns parâmetros são importantes no processo de classificação e aprendizagem das redes neurais da família ART, são eles:

- Parâmetro de escolha ($\alpha > 0$) – define a ordem de busca entre os nós da camada F_2 ;
- Parâmetro de vigilância ($\rho \in [0, 1]$) – define a seletividade do sistema. Quanto mais próximo de 1, mais seletivo será o sistema;
- Parâmetro de taxa de treinamento ($\beta \in [0, 1]$) – define a velocidade em que os pesos são reajustados. Para $\beta = 1$ o treinamento é considerado rápido.

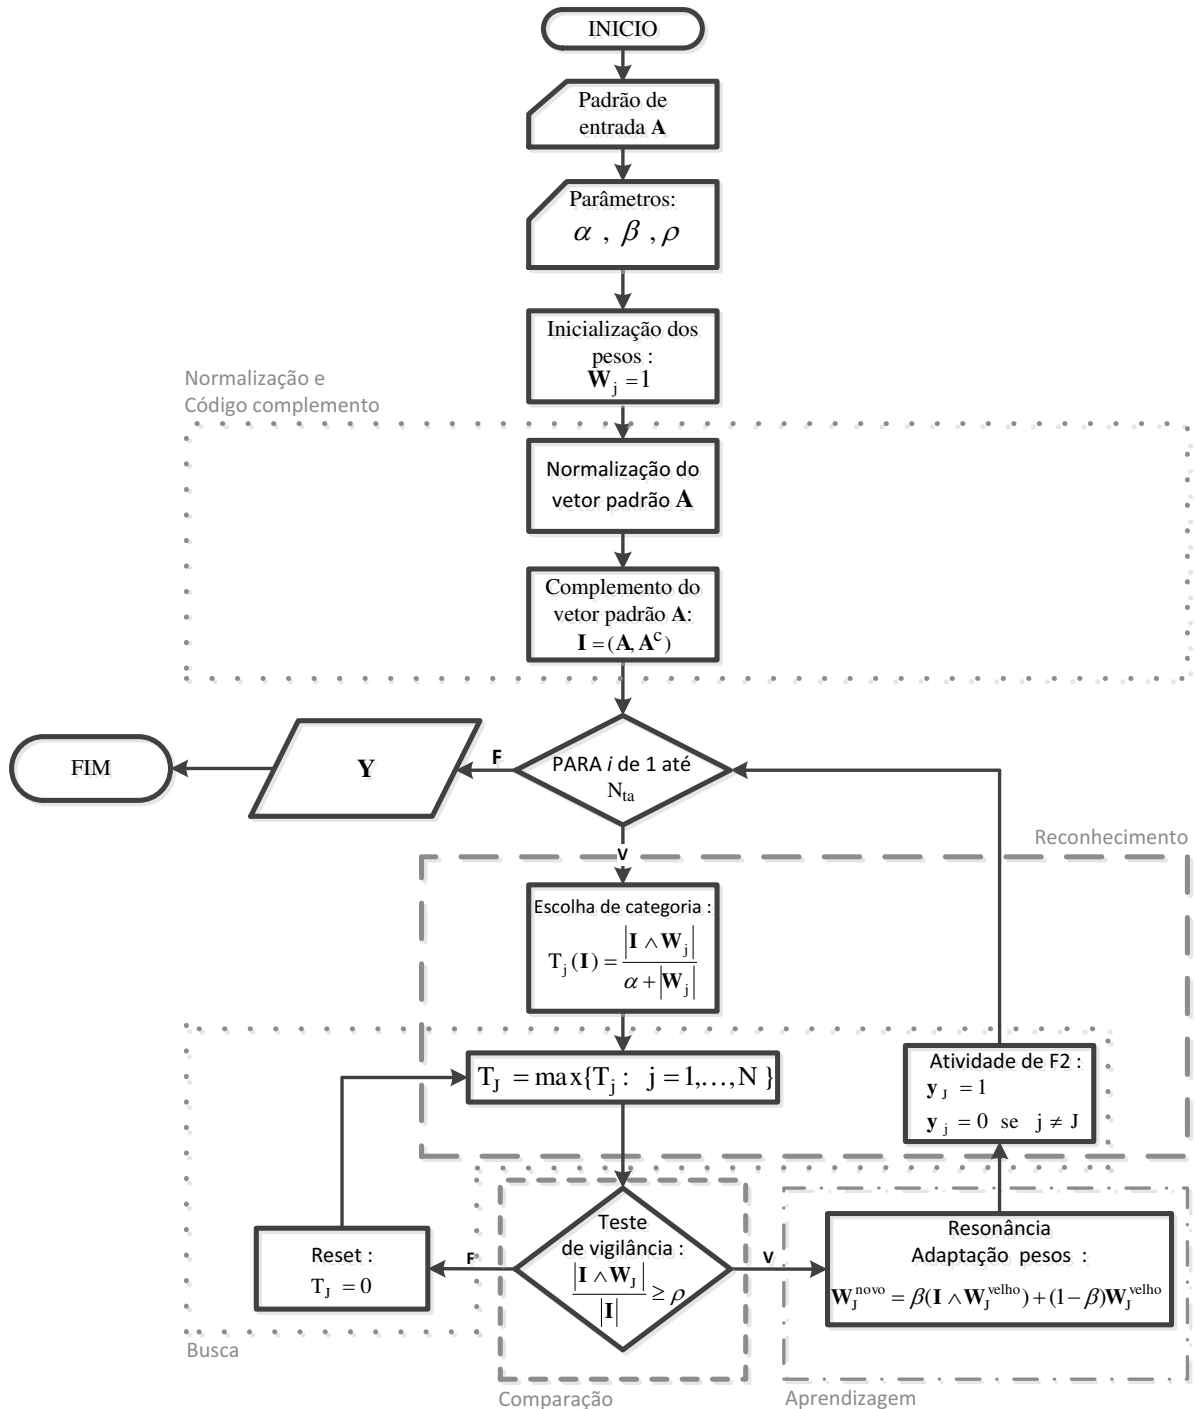
O processo de classificação de rede ART consiste em quatro fases principais (GROSSBERG, 1987), que podem ser vistos na Figura 3, onde é apresentado o algoritmo da rede neural:

- **Reconhecimento** : Esta etapa é responsável pelo reconhecimento dos estímulos produzidos no campo F_2 . Para isto, são calculados os elementos do

vetor utilizando a função escolha, a categoria selecionada é que obtiver o maior valor da função de escolha (GROSSBERG, 1987).

- **Comparação** : Responsável por testar a similaridade entre o vetor de entrada e o vetor de comparação (vetor de pesos), através do parâmetro de vigilância, que permite ou não a inclusão do padrão de entrada na categoria. Se não for aceito, de acordo com o critério de vigilância, outro neurônio deve ser encontrado para armazenar o referido vetor (GROSSBERG, 1987).
- **Busca** : Procura um novo neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio rejeitado é desativado desta seleção. O vetor de entrada é reapresentado, entrando na fase de comparação que termina apenas quando encontrar um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, se isso não for possível, esse vetor de entrada é considerado sem categoria (GROSSBERG, 1987).
- **Treinamento** : Existem dois aprendizados na rede ART, o aprendizado rápido, os pesos feedforward são ajustados para seus valores ótimos em poucos ciclos (geralmente apenas um ciclo de treinamento), e o aprendizado lento, onde os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento (GROSSBERG, 1987).

Figura 3 – Fluxograma do algoritmo de classificação da rede neural ART Fuzzy.



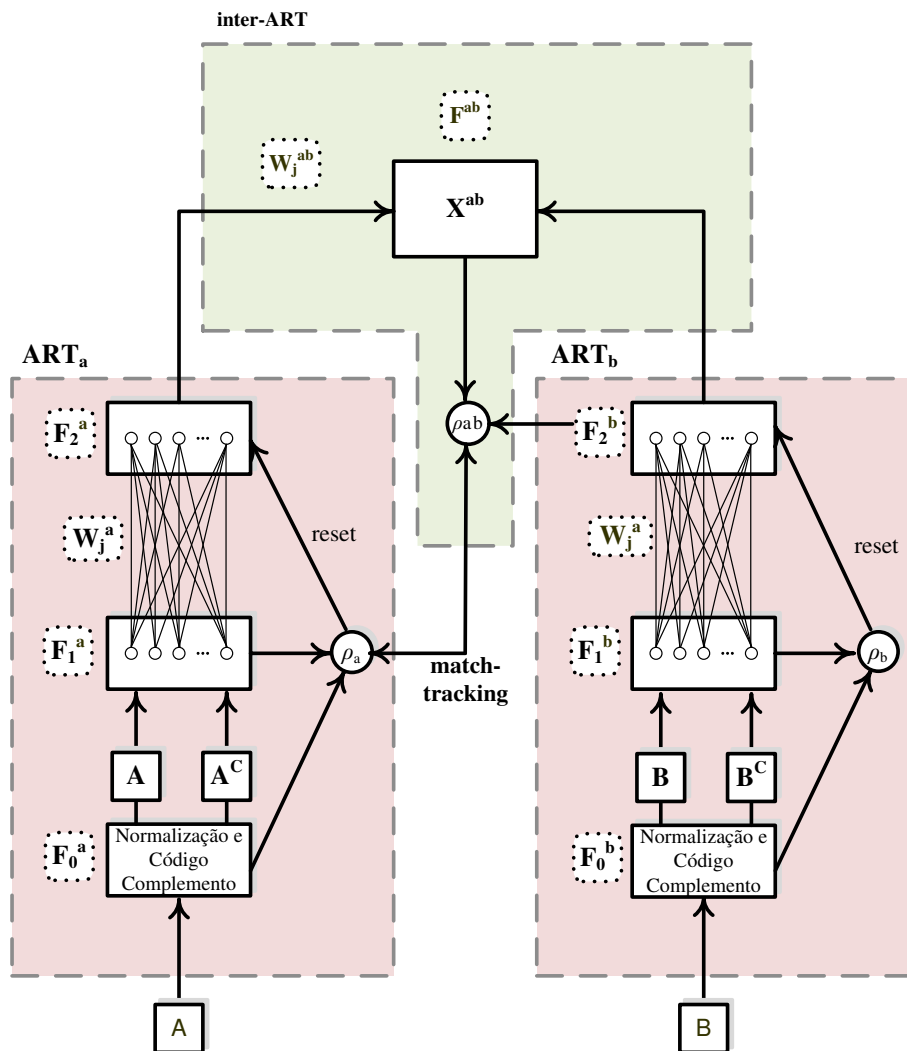
Fonte: Lopes (2005).

4.4 REDE NEURAL ARTMAP Fuzzy

Nesse modelo de rede, o aprendizado é do tipo supervisionado de dados binários e/ou analógicos através da pré-classificação dos dados de entrada e saída em categorias. Logo, tanto a entrada quanto a saída já são previamente conhecidas (CARPENTER; GROSSBERG, 1992).

Essa rede é formada por dois módulos ART, sendo um responsável pelo processamento do vetor de entrada, denominado ART_a , e outro para o processamento do vetor de saída desejada, denominado ART_b , classificando os dados de entrada e de saída. Possui o módulo de memória associativa denominado inter-ART (map Field), que realiza a conexão entre as categorias ativas de entrada (ART_a) e as categorias ativas de saída (ART_b). A rede neural ARTMAP Fuzzy possui a mesma concepção da rede ARTMAP convencional via substituição das operações de conjuntos por operações baseadas na lógica fuzzy, mais precisamente a permuta de operações de união e interseção pelos operadores Máx e Min fuzzy (CARPENTER; GROSSBERG, 1992). A arquitetura da rede ARTMAP Fuzzy pode ser vista na Figura 4.

Figura 4 – Arquitetura da rede ARTMAP Fuzzy.



Fonte: Lopes (2005).

A aprendizagem (ou treinamento) da rede ARTMAP fuzzy pode ser descrita, basicamente, em seis etapas: normalização dos vetores de entrada e de saída, execução do

código complemento, reconhecimento, comparação, busca e aprendizagem. O treinamento da rede é idêntico ao da rede ART, com a diferença apenas que possui um sistema de conexão entre os dois módulos ART existentes na rede, combinando os parâmetros de entrada e de saída, através do módulo match tracking, fazendo com que a rede tenha um treinamento supervisionado.

O módulo match tracking, mecanismo interno permite a rede elevar o parâmetro de vigilância ρ_a do módulo ART_a de forma a corrigir erro no módulo ART_b , sempre que a rede fizer um diagnóstico errado, maximizando, deste modo, a generalização e minimização do erro. O módulo ART_a inicia a busca até encontrar um diagnóstico correto ou a criação de uma nova categoria para a entrada atual.

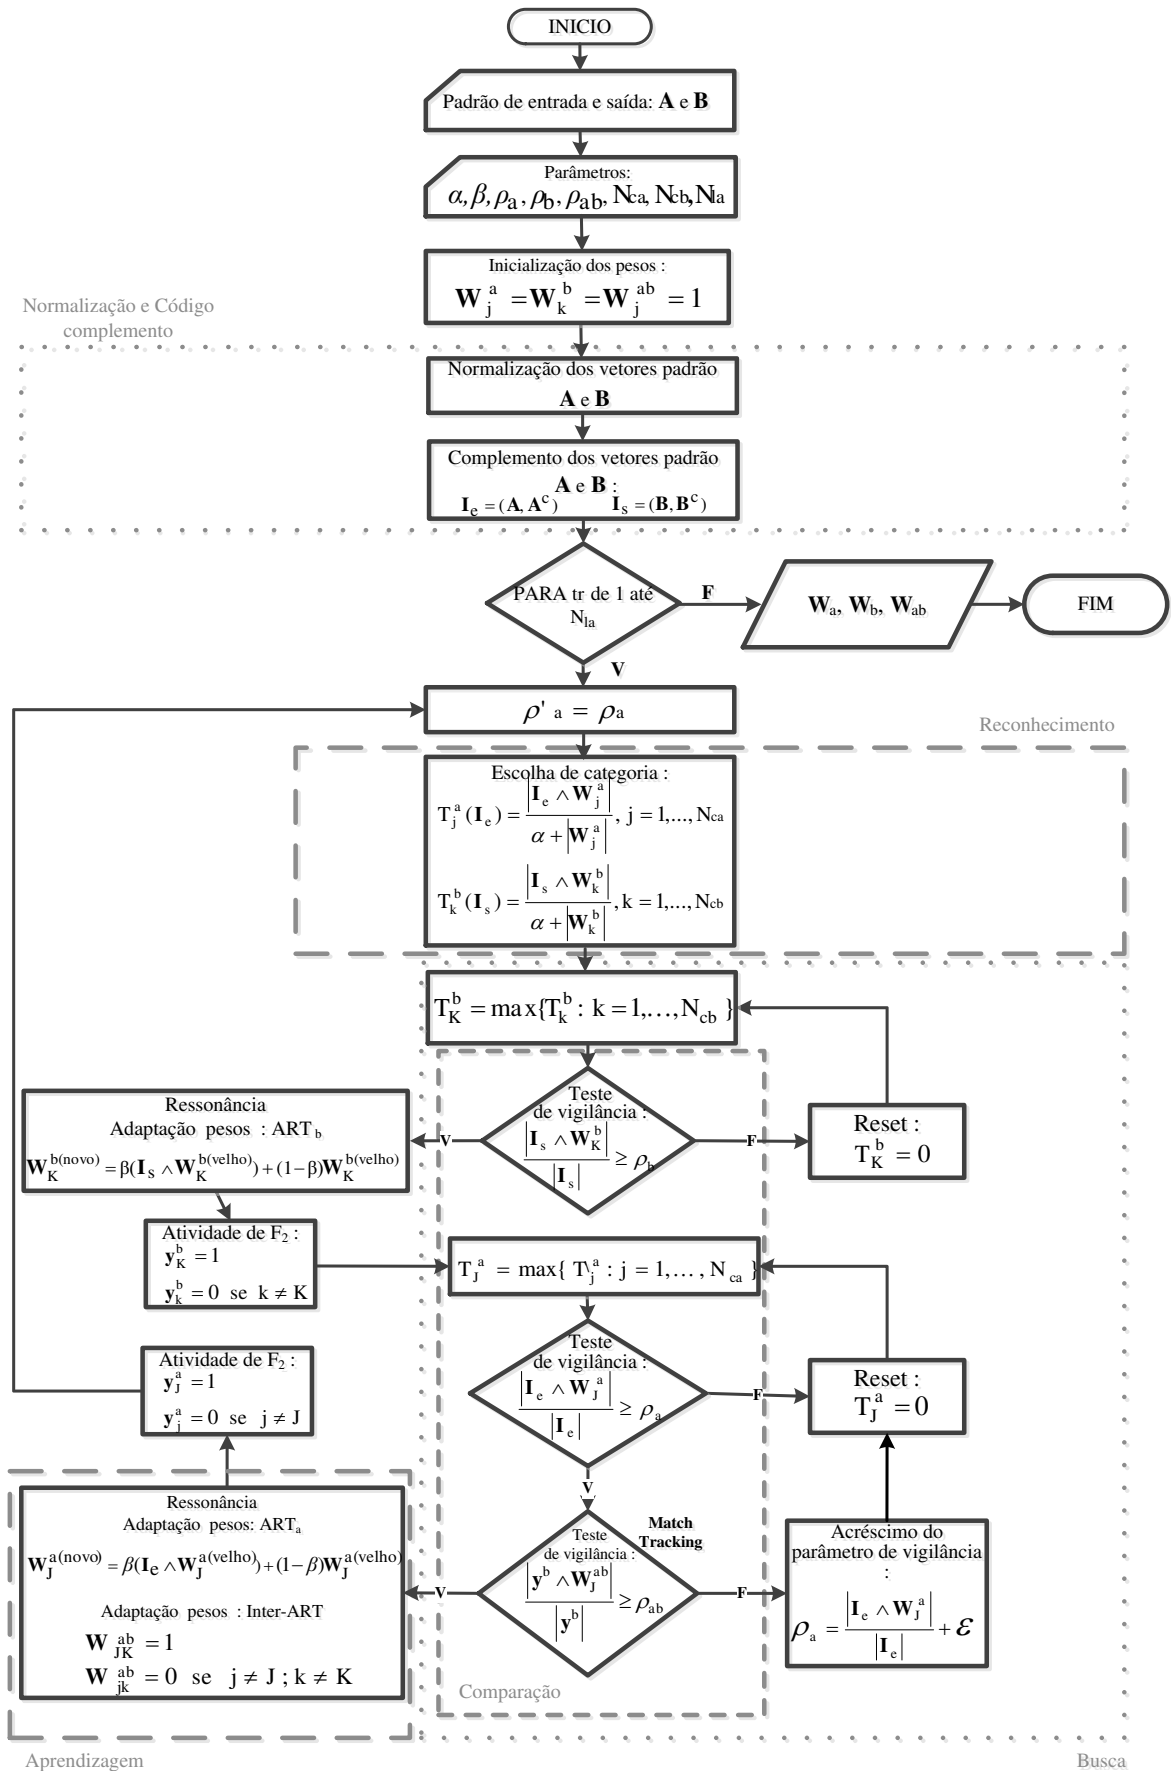
O módulo ART_a aprende a classificar os padrões de entrada apresentados, enquanto o módulo ART_b desenvolve as categorias referentes aos padrões de saída desejada. A camada inter-ART recebe entradas de ambos os módulos ART_a e ART_b , a entrada da ART_a refere-se à conexão associativa da $J \rightarrow K$ (categoria ativa J do ART_a e categoria ativa K do ART_b) e a categoria ativa da entrada do ART_b .

O fluxograma da ARTMAP Fuzzy é apresentado na Figura 5. Inicialmente é feita as leituras dos vetores de entrada e saída (**A** e **B**), dos parâmetros (α , β , ρ_a , ρ_b , ρ_{ab}); em seguida é feita a inicialização dos vetores de peso \mathbf{W}_j^a , \mathbf{W}_k^b e \mathbf{W}_j^{ab} (atribuindo 1 a todas posições dos vetores), representando categorias não-ativas. Os vetores de entrada **A** e saída **B** são normalizados e codificados com complemento, criando os vetores \mathbf{I}_e e \mathbf{I}_s , respectivamente, entrada e saída, onde o complemento é feito através da fórmula: $A_i^c = [1 - A_i]$ para vetor \mathbf{I}_e e $B_i^c = [1 - B_i]$ para o vetor \mathbf{I}_s .

A função escolha de categoria (T) da rede ART_a e ART_b é iniciada. Após o cálculo da função escolha, o sistema realiza a operação fuzzy com operador mínimo para T_K^b . Em seguida é feito o teste de vigilância da categoria escolhida, verificando se ela (a categoria) satisfaz o critério de vigilância com seu respectivo parâmetro de vigilância ρ_b , é feita a ressonância e atualização dos pesos \mathbf{W}_K^{novo} da rede ART_b , ativando categoria no vetor atividade \mathbf{Y}_K^b , onde K indica a categoria escolhida/vencedora ART_b . Se não for atendido o critério de vigilância é atribuído valor 0 (zero) a função de escolha T_K^b (inativando essa categoria). A busca continua até que a categoria K escolhida satisfaça o critério de vigilância. O procedimento é semelhante para escolha de categoria T_j^a com seus respectivos parâmetros e categorias da ART_a .

Após os testes de vigilância das redes ART_a e ART_b é realizado o procedimento “match tracking”, que testa o parâmetro de vigilância ρ_{ab} . Se houver ressonância é realizada a atualização da matriz de pesos W_j^{novo} da rede ART_a , e da Inter-ART W_{JK}^{ab} . Se não houver ressonância (o critério de vigilância não for atendido) a categoria T_j^a é desabilitada. Neste caso, o parâmetro de vigilância do módulo ART_a é elevado em uma quantidade mínima ε ($\varepsilon > 0$) para corrigir o erro no módulo ART_b e a busca continua para próxima categoria. O módulo ART_a inicia a busca até encontrar um prognóstico correto ou a criação de uma nova categoria para a entrada atual.

Figura 5 – Fluxograma da rede neural ARTMAP Fuzzy



Fonte: Lopes (2005).

5 METODOLOGIA PARA PREVISÃO DE CARGA

5.1 INTRODUÇÃO

O modelo proposto, nesta pesquisa, encontra-se ilustrado na Figura 6. Trata-se de um procedimento que combina o uso do sistema de previsão de cargas proposto em Altran (2010) e a rede neural ART-ARTMAP-Fuzzy visando à realização da previsão multinodal. A vantagem desta concepção, a princípio, consiste em realizar a previsão multinodal com um tempo de processamento muitíssimo reduzido, se comparado à formulação via rede neural retropropagação (WERBOS, 1974), a qual representa a grande maioria dos artigos publicados para a previsão global.

Uma das dificuldades encontradas sempre tem sido a base de dados para realizar treinamento e previsão de cargas. A base de dados escolhida é da Nova Zelândia. Ela foi disponibilizada em 2009, e desde então tem sido utilizado em algumas pesquisas do grupo de pesquisa junto ao laboratório SINTEL (Sistemas inteligentes) da Unesp - Câmpus Ilha Solteira.

5.2 BASE DE DADOS

Os dados históricos foram extraídos do Centralized Dataset (CDS) (2010) disponibilizados pelo Electricity Commission da Nova Zelândia. Essa base de dados contém os valores de potência ativa, medidos de meia em meia hora de cada subestação, além das informações referentes ao dia do mês, mês, ano, dia da semana, feriado, horário de verão e valor da amostra de carga. Como os valores são medidos de meia em meia hora, as amostras para um dia (24 horas) correspondem a 48 amostras.

Esses dados formam variáveis de entradas da rede neural modeladas de modo similar às utilizadas por Nose-Filho (NOSE-FILHO, 2010; NOSE-FILHO; LOTUFO; MINUSSI, 2011c) e Altran (ALTRAN, (2010). No Apêndice E é mostrado, de forma detalhada, o estudo feito por Nose-Filho (2010) e Nose-Filho, Lotufo e Minussi (2011c) para realizar a modelagem dos sinais de entrada tanto para treinamento como para previsão da rede neural.

A base de dados foi dividida em duas partes: treinamento e validação/teste, o conjunto de dados para treinamento usado para treinar a rede neural foram os dias 01-01-2007 a 31-12-2008 e o conjunto escolhido para validação/teste foram os dias 08 a 14-01-2009.

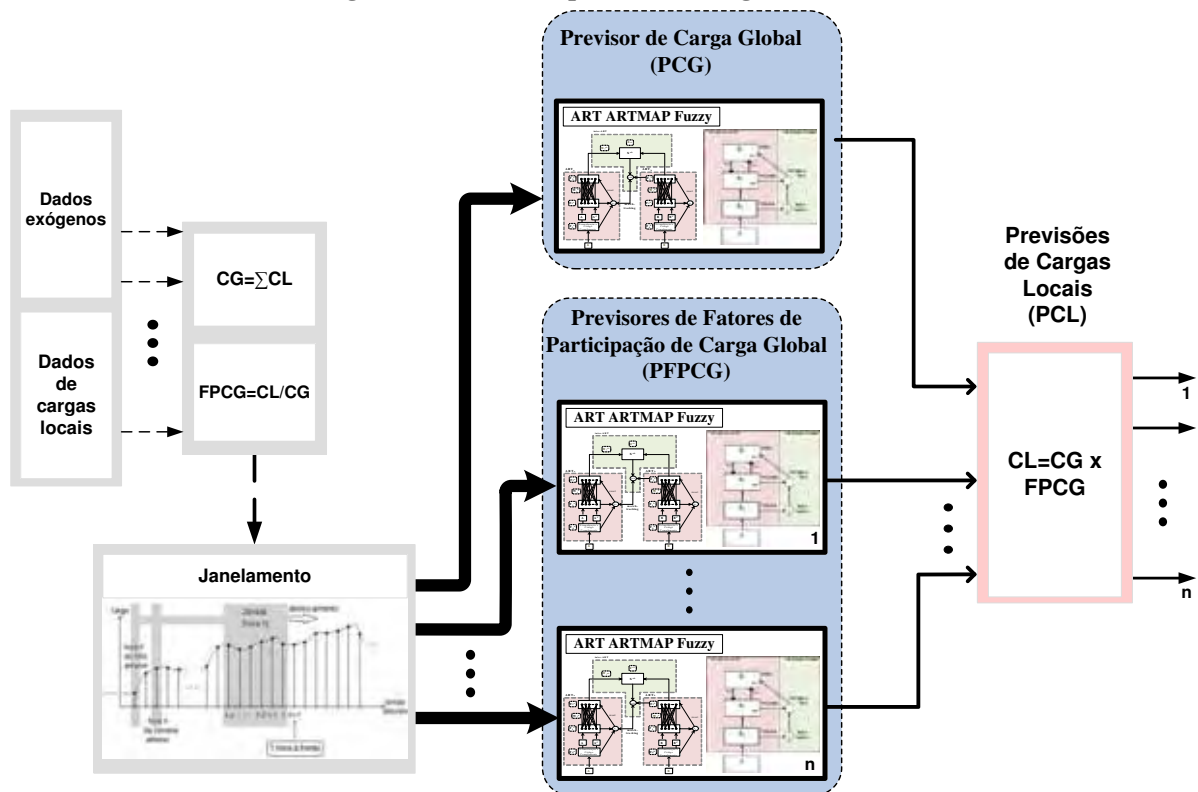
Porém apenas alguns desses dias, em especial o dia 08 de janeiro de 2009, é mostrado no capítulo de simulações e resultados.

5.3 SISTEMA PREVISOR

Este sistema é composto por dois grandes blocos (Figura 6): (1) Previsor de Carga Global (PCG); (2) Previsor de Fator de Participação de Carga Global (PFPCG). Módulo PCG realiza a previsão de carga global (CG) do sistema, o módulo PFPCG realiza previsão dos fatores de participação da carga global, para depois calcular a previsão da carga local (CL). Cada módulo previsor possui sua própria rede neural para treinamento (ARTMAP Fuzzy) e previsão (ART-Fuzzy).

O sistema possui um paralelismo natural, ou seja, uma vez concluído o treinamento do módulo PCG, os módulos PFPCG podem ser treinados e operados de forma independente.

Figura 6 – Sistema previsor de carga multinodal.



Fonte: da própria autora.

O treinamento e execução do módulo PCG seguem o modo convencional. Na fase de treinamento dos módulos PCG e PFPCG são utilizados os valores de carga global e local real, respectivamente. Na fase de previsão são utilizados na entrada, os valores de carga global e

local previsto utilizando o deslocamento de janela. Uma vez concluído o treinamento do sistema previsor global, é realizado o treinamento dos módulos locais.

Cada módulo PFPCG é treinado de forma independente, usando as informações disponíveis (séries históricas da potência da carga, dados climáticos, tipo de consumidor, etc.), em que são estabelecidas as estimativas das cargas por barramento (carga local). Determinando o Fator de Participação da Carga Global (FPCG) para cada nó de interesse, ou seja, $FPCG_j$, $j = 1, 2, \dots, n$ (n : número de nós/barramentos). Estes fatores são representados por séries temporais que são usadas para estimar a carga em cada nó, bem como servir para outros estudos de interesse, em geral, dinâmica e classificação das cargas (ALTRAN, 2010).

No PFPCG, a entrada de cada módulo, para a fase de treinamento, é composta pelos valores das cargas (dados históricos) e dados referentes ao tempo (dia da semana e hora). Para a fase do diagnóstico, a entrada é composta pelo vetor de saída do sistema previsor global que, por sua vez, geram, como saída, a carga local prevista estimada a partir do FPCG.

Conforme mencionado anteriormente, em cada módulo local, a estimativa do FPCG é determinada, também, usando-se redes neurais. Desta forma, o conjunto de cargas locais (CL) é definido como carga global (CG), dada pela equação (1), sendo que N é o número de barramentos. Cada carga possui um fator de participação da carga global, dado pela equação (2):

$$CG = \sum_{j=1}^N CL_j \quad (1)$$

$$FPCG_j = CL_j / CG, \quad j = 1, 2, \dots, N \quad (2)$$

O funcionamento desta proposta é baseado na seguinte ideia. Um módulo principal realiza o treinamento e a respectiva previsão da carga global, conforme pode ser visualizado na Figura 6 (primeiro módulo de cima para baixo). O treinamento e a previsão nos barramentos (previsão multimodal) são executados pelos demais módulos (do segundo em diante). Ressalta-se que todos estes módulos, inclusive o de previsão global, podem ser processados de modos independentes, ou seja, constituem-se de um paralelismo perfeito. O $FPCG_j$ (equação (2)), conjuntamente com o valor da carga global, formam o vetor de entrada de cada módulo para previsão do barramento j . Assim, a dimensão do vetor de entrada, de

cada módulo para a previsão multinodal, é bem inferior ao empregado na previsão global. Por exemplo, supondo-se que a janela usada for de 3 valores das cargas passadas, a dimensão da entrada do módulo previsor global é 22 (conforme pode-se verificar na Figura 7 adiante), enquanto do barramento j é 4.

Além disto, este procedimento torna-se vantajoso, pois o comportamento dos FPCG's é, via de regra, mais "suave", se comparado ao comportamento das cargas locais. Deste modo, o treinamento da rede neural torna-se mais rápido e trabalha com um menor número de informações, i.e., os estímulos de entrada são compostos por um número menor de componentes (ALTRAN, 2010).

O treinamento destas redes locais é bastante simples, visto que a entrada é composta por dados locais, que são particularidades de cada nó, e pela série temporal da carga elétrica global, determinada pelo sistema de previsão global, constituindo entradas de dimensão reduzida. Os dados locais podem conter, também, informação que possam contribuir para a melhoria do modelo da carga nodal, ou seja, podem-se usar vários tipos de estratégias, inclusive, outros dispositivos inteligentes.

Com esta concepção, evidentemente, há necessidade de dispor de módulos neurais que apresentem qualidades fundamentais: confiabilidade e rapidez na obtenção da solução. A carga de cada nó considerado de interesse pode ser estimada (prevista) multiplicando o FPCG pelo valor da carga global prevista pelo módulo PCG em cada instante da série temporal. Uma comparação do uso do FPCG e da carga local pode ser em visto em Antunes e Minussi (2012), onde os resultados de previsão foram melhores quando aplicado o FPCG, ao invés de utilizar a carga local (normalizada) diretamente nas fases do treinamento e da previsão.

A fase da previsão das cargas locais é realizada da seguinte forma:

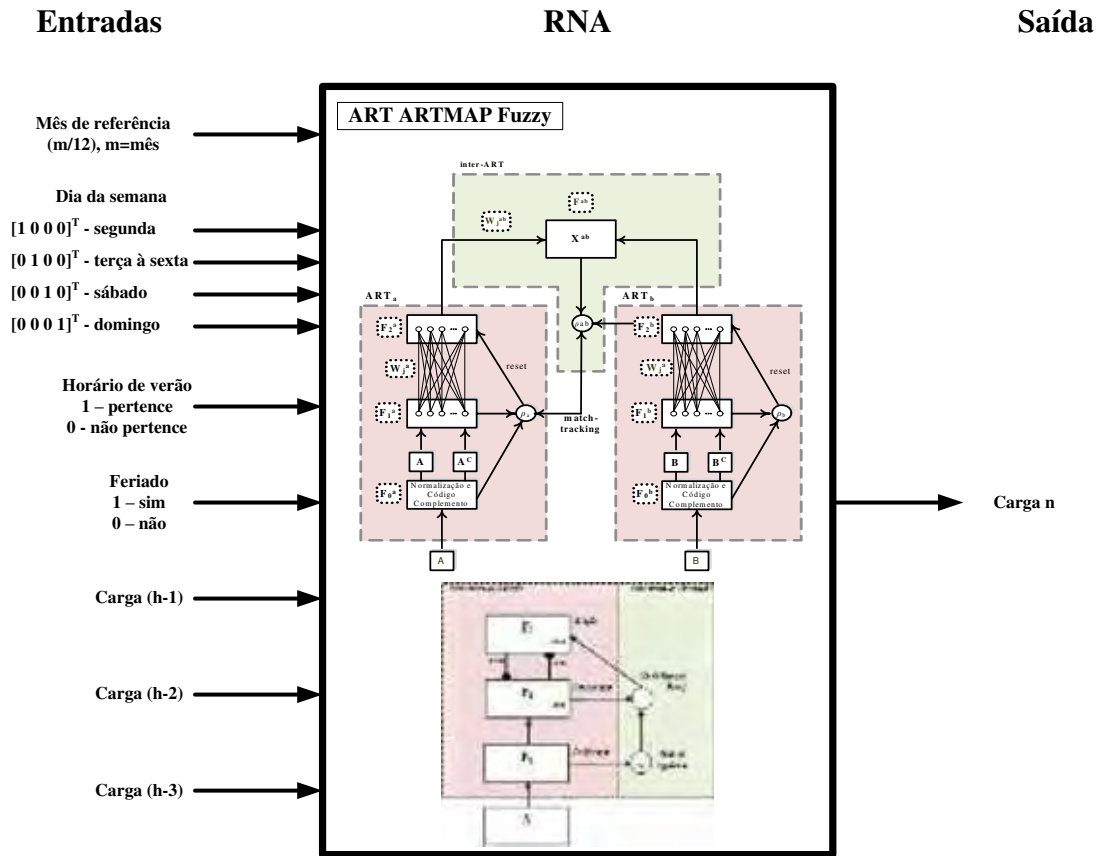
1. Execução da previsão da carga global $\rightarrow PCG^{(previsão)}(h)$, para h compreendendo toda a série histórica adotada (ALTRAN, 2010);

2. Tomando-se os valores da carga global e as entradas locais, é realizada a previsão dos FPCG's referentes a cada nó, ou seja, $FPCG_j^{(previsão)}(h)$, $j = 1, 2, \dots, n$. Após a conclusão da fase de treinamento, a carga local horária de pode ser estimada pela equação (3):

$$CL_j^{(previsão)}(h) = FPCG_j^{(previsão)}(h) \times PCG^{(previsão)}(h) \quad (3)$$

Os vetores de entrada e saída do sistema predictor são descritos na Figura 7, esses são compostos pelos dados históricos das cargas (janela de carga composta por três valores de carga passadas) e os dados exógenos (mês de referência, dia da semana, horário de verão, feriado, número da amostra). A saída corresponde com a carga prevista (Carga n), que corresponde as 48 amostras da carga (medidas de 30 em 30 minutos) do dia escolhido. No módulo PCL a saída é o FPCG previsto, para encontrar a previsão de carga de cada nó basta multiplicar o FPCG previsto pelo valor da carga global prevista em cada instante da série temporal.

Figura 7 – Definição das entradas/saída da rede neural artificial.



Fonte: da própria autora.

As cargas foram normalizadas através da equação (4). O valor máximo da carga dos anos de 2007 e 2008 é multiplicado por 1,2 por medida de segurança para que não se tenha valores de cargas normalizadas igual a 1.


$$\overline{carga}(n) = \frac{carga(n)}{1,2 \times (\max(carga(2007,2008)))} \tag{4}$$

sendo:

$\max(\text{carga}(2007,2008))$ – corresponde a maior carga dos anos de 2007 e 2008.

Os dados históricos das cargas podem ser usados tomando-se o procedimento mais usual na área de previsão de carga, que é o método do movimento de uma janela (Figura 8) (DJUKANOVIC et al., 1995; PARK, EL-SHARKAWI, MARKS, 1991), o deslocamento padrão utilizado é de uma hora à frente, mas o deslocamento aplicado nesse trabalho avalia resultados com duas, três e quatro janelas, ao invés de uma janela, onde h é a hora atual, $h+1$ é carga prevista, p é o tamanho da janela.


Figura 8 – Previsão de carga via deslocamento da janela.



Fonte: da própria autora.

A Figura 9 mostra o deslocamento de uma janela de tamanho 3 (com três cargas para realizar a previsão “um passo à frente”). Nas três primeiras janelas é necessário tomar as amostras de carga passada do dia anterior. Por exemplo, a primeira janela é composta pelas cargas das três últimas amostras do dia anterior (ou seja, amostras de número 46, 47 e 48). Com isso (e mais algumas informações) tem-se como resultado a previsão 1; na segunda janela tem-se a carga prevista na janela 1 e apenas duas cargas do dia anterior (amostras 47 e 48), resultando na previsão 2; na terceira janela tem-se a carga prevista na janela 1 e janela 2, resultando na previsão 3. A partir da quarta janela tem-se as cargas previstas das janelas anteriores correspondentes, resultando sempre na carga prevista que é usada até a penúltima amostra, amostra 47.

Figura 9 – Deslocamento das janelas.



Fonte: da própria autora.

6 SIMULAÇÕES E RESULTADOS

6.1 INTRODUÇÃO

Para avaliar a metodologia proposta de previsão de carga multinodal, as redes neurais foram treinadas com dados referentes aos anos de 2007 e 2008 para realizar a previsão de um dia à frente (24 horas à frente), não necessariamente foi o dia 01 de janeiro de 2009 (primeiro dia subsequente ao término do treinamento), ou seja, é possível escolher qualquer ponto (dia) adiante para ser previsto. Para realizar a previsão, basta dispor as cargas que compõem a primeira janela.

Nesse sentido, foram realizadas várias previsões em outros dias e meses do ano de 2009, porém apenas a carga global e a carga local previstas do dia 08 de janeiro de 2009 foi aplicada nesse trabalho.

6.2 SIMULAÇÃO

A rede neural ART-ARTMAP Fuzzy foi implementada no programa MATLAB como duas funções, onde uma é responsável pelo treinamento (Rede ARTMAP) e a outra pela previsão (Rede ART).

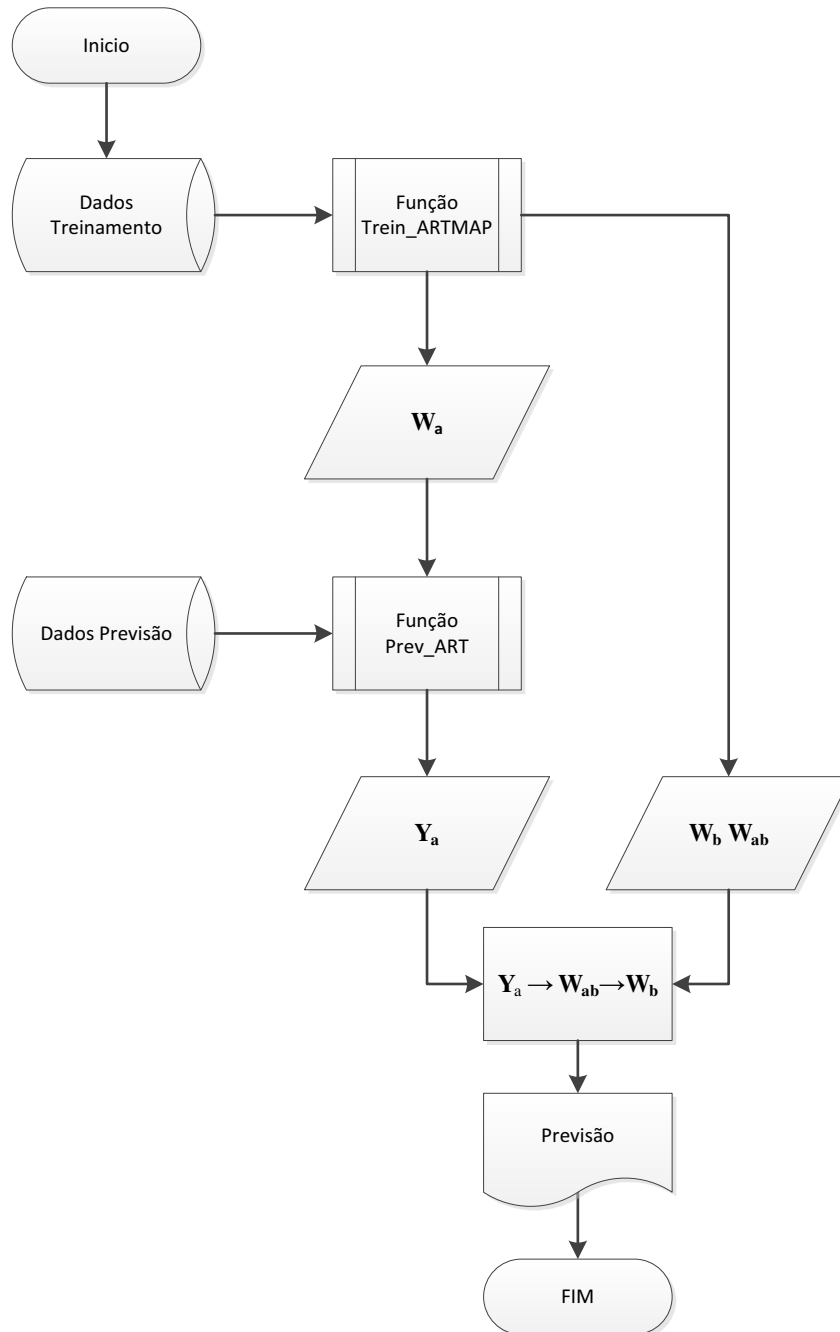
Na Figura 10 mostra-se, de forma resumida, o funcionamento do sistema, em que os dados de treinamento (2007 e 2008) são alimentados e enviados para função de treinamento (Trein_ARTMAP). Gerando matriz de pesos, a matriz W_a é enviada para função de previsão (Prev_ART) que recebe também os dados de previsão (validação/teste) para realizar a previsão gerando a saída da rede (Y_a) que, juntamente com a saída (matriz de pesos W_b e W_{ab}) da função de treinamento, resulta no valor da carga prevista pela rede neural

Na Figura 11, após execução da função de previsão, foi colocada uma condicional para verificar se a previsão calculada é aceita, para previsão global o erro permissível foi de até 2%. Para previsão local foi definido o erro permissível de até 4%. Esses valores foram escolhidos após constatar a frequência de ocorrência dos mesmos nos resultados de erros percentuais das previsões obtidas nos primeiras execuções da rede neural (sem a condicional).

A condicional criada funciona da seguinte forma: se o erro (erro1) calculado na previsão for maior que o erro predefinido, a previsão realizada é armazenada e refaz-se a previsão só que com a janela utilizando o deslocamento de janela da base de dados. Então, o erro (erro2) é calculado novamente. Se esse erro (erro2) for menor que o primeiro erro

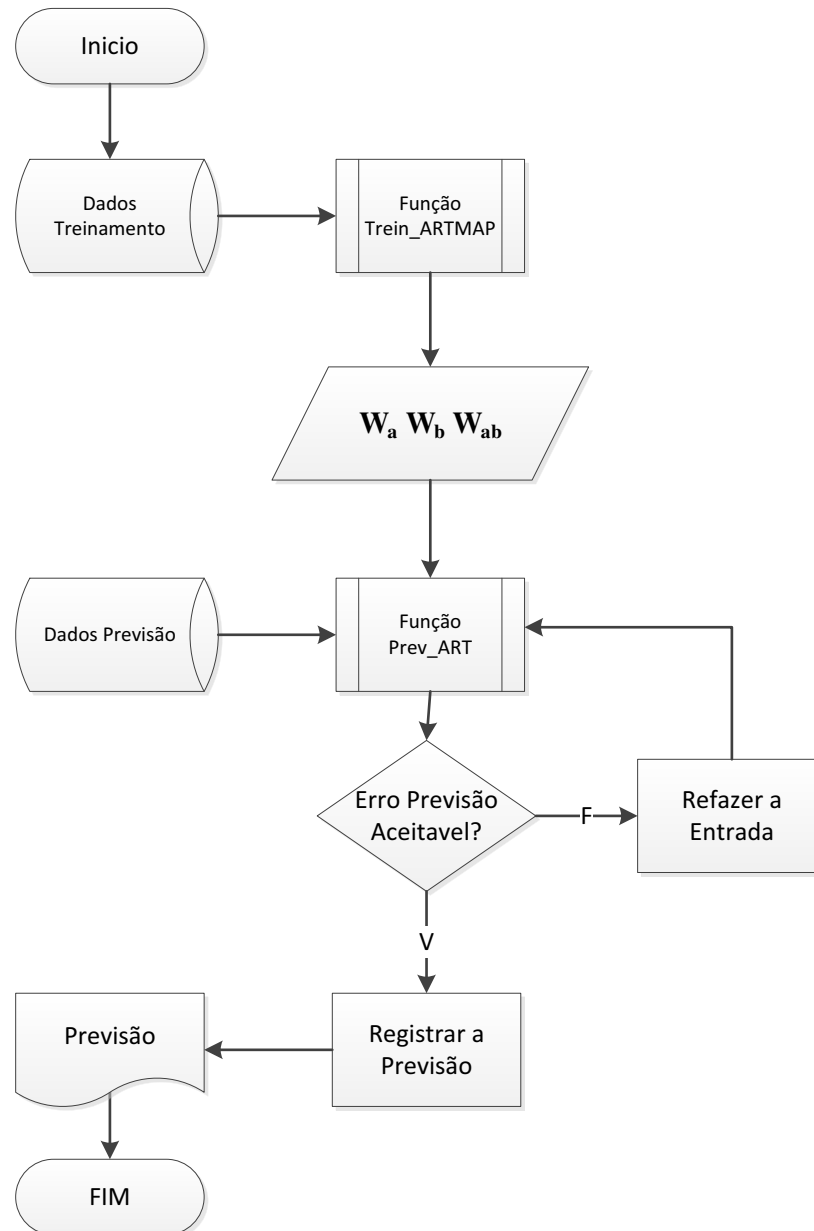
calculado (erro1), deve-se armazenar essa previsão. Caso contrário, se não for melhor, ou seja, o valor calculado pela primeira previsão é melhor, armazena-se a primeira previsão.

Figura 10 – Esquema de funcionamento do treinamento e previsão das redes neurais.



Fonte: da própria autora.

Figura 11 – Funcionamento do método condicional implementado.



Fonte: da própria autora.

6.3 PARTICLE SWARM OPTIMIZATION

PSO é uma técnica de inteligência de enxames que busca inspiração no comportamento de locomoção, por exemplo, de um bando pássaros ou um cardume de peixes quando viajam de um lugar para outro (KENNEDY; EBERHART, 1995).

O algoritmo da PSO trata cada indivíduo da população como um ponto (chamado partícula) constituído de uma posição e uma velocidade inicial no espaço busca, que percorre

o sistema procurando a região onde a função-objetivo atinge os melhores resultados do problema analisado. A função-objetivo definida para avaliar a qualidade da posição da partícula depende do problema a ser otimizado. Cada partícula i é representada num espaço busca \mathbb{R}^n por dois vetores n -dimensionais que armazenam, respectivamente, a posição e a velocidade atual da partícula. A tomada de decisão, sobre qual trajetória as partículas devem seguir, baseia-se na experiência pessoal de cada componente do grupo e na influência que cada partícula sofre com o comportamento de todos outros elementos do grupo. A partir disso, para atualizar a posição e a velocidade de cada partícula emprega-se as equações (5) e (6).

$$v_i^{q+1} = w^q v_i^q + c_1 r_1 (p_i^q - s_i^q) + c_2 r_2 (p_g^q - s_i^q) \quad (5)$$

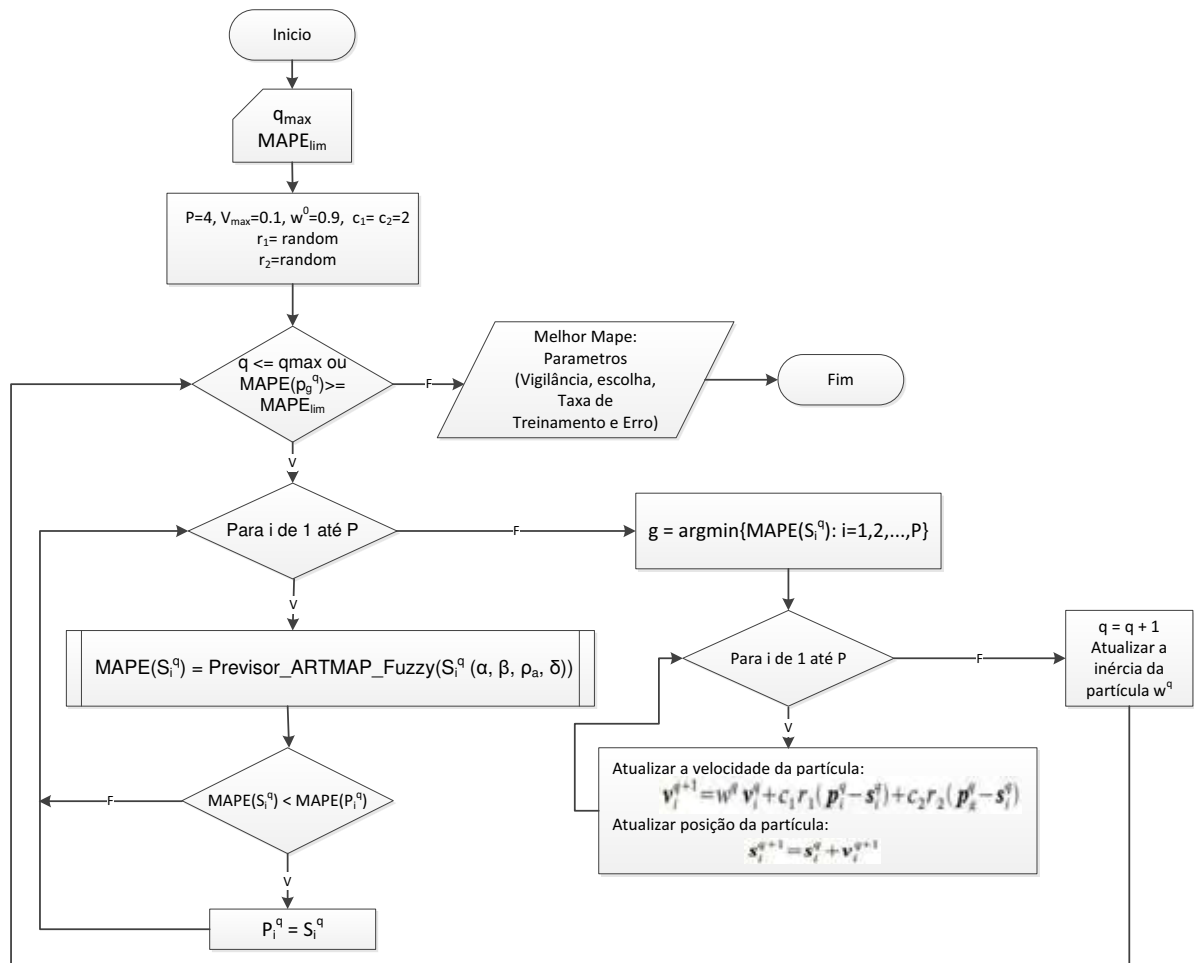
$$s_i^{q+1} = s_i^q + v_i^{q+1} \quad (6)$$

Sendo: s_i^q representa a posição atual de cada partícula i , v_i^q define a velocidade atual de cada partícula i , p_i^q indica a melhor posição pessoal, p_g^q indica a melhor posição do enxame, c_1 e c_2 representam constantes positivas conhecidas, respectivamente, como parâmetros cognitivo e social, r_1 e r_2 são números aleatórios distribuídos uniformemente entre 0 e 1. O parâmetro w^q regula a capacidade de busca no espaço \mathbb{R}^n . Quando se atribui um peso alto, tende a realizar uma busca numa região mais abrangente, enquanto um peso pequeno ocasiona uma busca numa região mais delimitada.

O algoritmo utilizado na aplicação foi elaborado por Granger et al. (2007), com a devida adaptação para o problema de previsão de cargas. O fluxograma do modelo proposto é descrito na Figura 12. Primeiramente, é selecionada a estratégia de aprendizagem interna (única época), configurado o número máximo de iterações (q_{\max}) e função-objetivo ótima (Mape_{lim}), configurado parâmetros do PSO (P , V_{\max} , w^0 , c_1 , c_2 , r_1 e r_2). Com essas informações, é dado início ao processo das iterações, onde cada partícula realiza o treinamento e a previsão da rede neural ART-ARTMAP, retornando o MAPE que é armazenado para ser comparado com MAPE obtido por outras partículas. Seleciona-se a partícula que obteve o melhor MAPE local e atualizado as melhores posições (parâmetros) encontradas. Após cada iteração, verifica-se qual foi o melhor MAPE global entre todas as partículas. Na sequência, atualiza-se a velocidade e a posição. O processo termina apenas quando finaliza o número de iterações ou é encontrado um MAPE que satisfaça o limite estipulado.

Os parâmetros utilizados pelo PSO são os parâmetro de vigilância da rede ART_a (ρ_a), parâmetro de escolha (α), taxa de treinamento (β) e o parâmetro de erro (ε) que incrementa o parâmetro de vigilância da rede ART_a. Eles são gerados de forma aleatória e armazenados para serem testados pela rede neural ART-ARTMAP Fuzzy. Ao finalizar a execução do algoritmo é alcançado o melhor MAPE e com ele os parâmetros que geraram esse MAPE.

Figura 12 – Modelo PSO-GLF

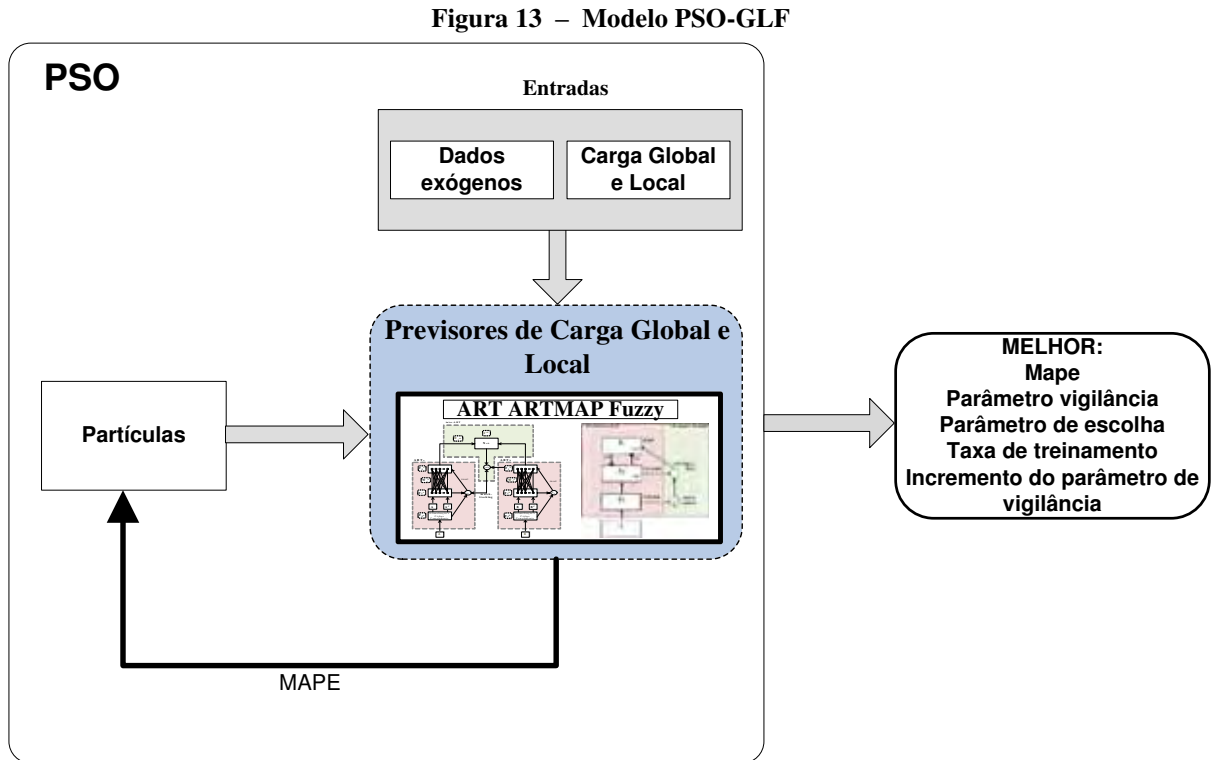


Fonte: Granger et al. (2007).

O sistema possui dois módulos principais. O primeiro é denominado PSO e o segundo é denominado PCGL (Previsores de Carga Global e Local). A execução do sistema é descrito a seguir (Figura 13):

- 1) Módulo PSO é iniciado e envia a entrada de dados ao Modulo de Previsão Global e Local (PCGL);
- 2) Módulo PCGL realiza a previsão global e local, de acordo com o número de iterações e partículas inicializadas;

3) Ao finalizar as iterações, tem-se como resultados os melhores parâmetros (vigilância, escolha, taxa de treinamento e erro) encontrados, de acordo com a estabilidade do MAPE.



Fonte: Antunes, Araújo, Minussi (2013).

Os principais parâmetros, utilizados para treinamento e diagnóstico da rede neural ART-ARTMAP Fuzzy desenvolvida, são apresentados na Tabela 1. Esses valores foram encontrados utilizando a técnica de otimização por enxame de partícula conforme artigo de Antunes, Araújo e Minussi (2013), onde foi encontrado os melhores parâmetro de escolha (α), de vigilância ART_a (ρ_a) e acréscimo de ρ_a (ϵ). Através da escolha desse conjunto de parâmetros, obteve-se o menor MAPE de previsão em uma base de dados reduzida (30% da base total).

Tabela 1 – Parâmetros utilizados pela rede neural ART-ARTMAP Fuzzy.

Parâmetros	Valores
Taxa de treinamento (β)	1
Parâmetro de escolha (α)	0,0819
Parâmetro de vigilância inicial do módulo ART_a (ρ_a)	0,0728
Parâmetro de vigilância do módulo ART_b (ρ_b)	1
Parâmetro de vigilância do módulo ART_{ab} (ρ_{ab})	1
Acréscimo de ρ_a (ϵ)	0,0992
Número de vetores de entrada referente à fase de treinamento	35040

Fonte: da própria autora.

Após a escolha desse conjunto de parâmetros foi aplicado o treinamento utilizando a base de dados completa, ou seja, todas as amostras do ano de 2007 e 2008.

6.4 RESULTADOS

Como critério de avaliação foi utilizada a média dos valores absolutos dos erros percentuais – MAPE (Mean Absolute Percentage Error) e o erro máximo da previsão diária - Emax (SRINIVASAN et al., 1998), comparando-se os valores reais da carga com os valores previstos através da rede neural, usando-se as equação (7) e (8), respectivamente.

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{100 \cdot |C^{Real}(n) - C^{Previsto}(n)|}{C^{Real}(n)} \quad (7)$$

$$Emax = \max \left(\frac{100 \cdot |C^{Real}(n) - C^{Previsto}(n)|}{C^{Real}(n)} \right), n = 1, \dots, N \quad (8)$$

sendo:

C^{Real} : o valor da carga real;

$C^{Previsto}$: o valor da carga prevista;

N : : Número de amostras previstas.

Foi realizado o treinamento e a previsão local para as nove subestações e com isso foram obtidos os MAPEs para cada subestação. Ao realizar o janelamento nos vetores de entrada e saída dos sistemas, espera-se obter valores de MAPE e Emax dentro dos padrões encontrados na literatura.

Quanto ao deslocamento de janela, foram realizadas simulações com três tamanhos diferentes de janelas para verificar quais alcançariam melhores resultados. Foram utilizados janelas de três tamanhos: dois, três e quatro. Os resultados apresentados a seguir foram obtidos utilizando três janelas por esse motivo foram colocadas as previsões locais e previsão global desse janelamento, conseguindo os melhores MAPEs na maioria das subestações.

O tempo de processamento para realizar a previsão por subestação e global, comparado à previsão global, foi semelhante para todas as subestações, com exceção da subestação nove que apresentou o tempo superior.

Na Tabela 2 são apresentados os MAPEs e o erro máximo percentual da previsão diária (E_{max}) de cada subestação e o global. Os valores alcançados foram satisfatórios, se comparado com a literatura especializada, com exceção novamente da subestação 9, onde o MAPE foi de 8,08% e o erro máximo foi de 21,22%. Erro máximo percentual apresentou altos valores em algumas amostras apenas da previsão, esses pontos podem ser tratados e estudados posteriormente para se verificar o que pode ser melhorado.

Tabela 2 – MAPEs e erro máximo previsão global e local.

Subestação	Sistema PG-FPCG-PCL	
	Mape (%)	E _{max} (%)
# 01	2,62	10,85
# 02	4,01	12,90
# 03	2,33	15,41
# 04	2,08	6,57
# 05	1,77	3,95
# 06	2,18	8,06
# 07	1,62	3,78
# 08	2,84	7,26
# 09	8,08	21,22
Global	1,12	2,56

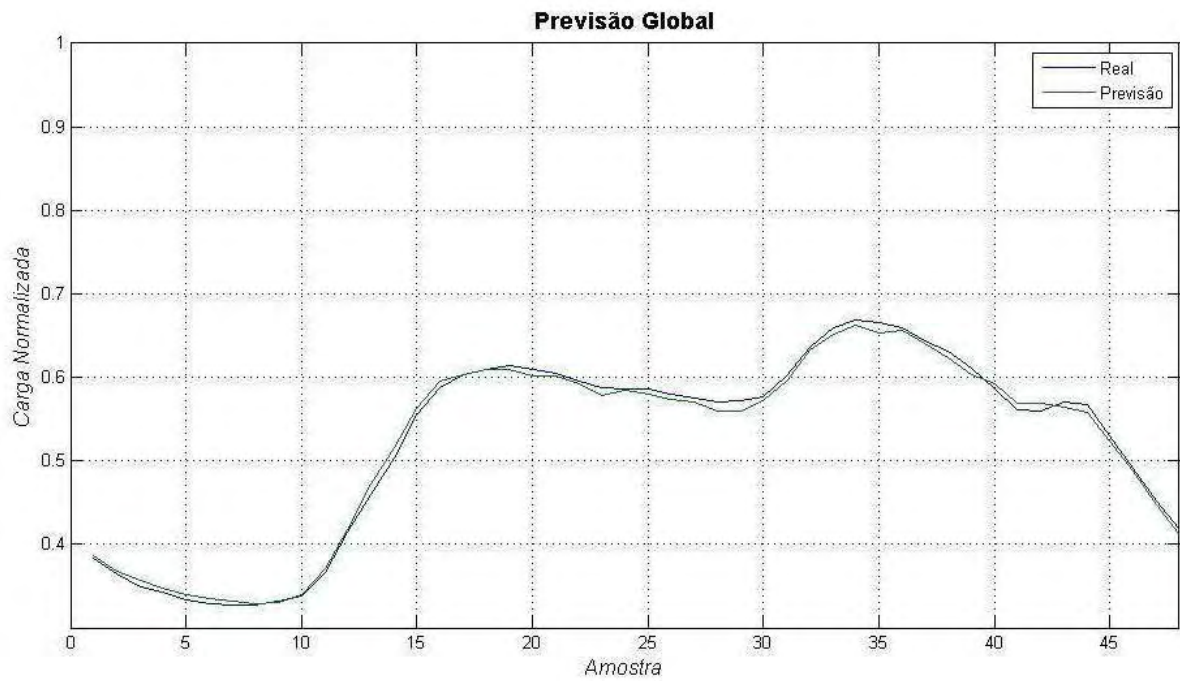
Fonte: da própria autora.

Os resultados da previsão de carga global e o percentual de erro podem ser observados, respectivamente, nas Figuras 14 e 15. Estes resultados foram obtidos utilizando o deslocamento de janela de tamanho igual a três. Ambos apresentaram excelentes resultados de previsão global e erros percentuais, abaixo de 2%, em grande parte das 48 amostras previstas do dia 08/01/2009.

O erro percentual, adotado nestes experimentos, é dado por:

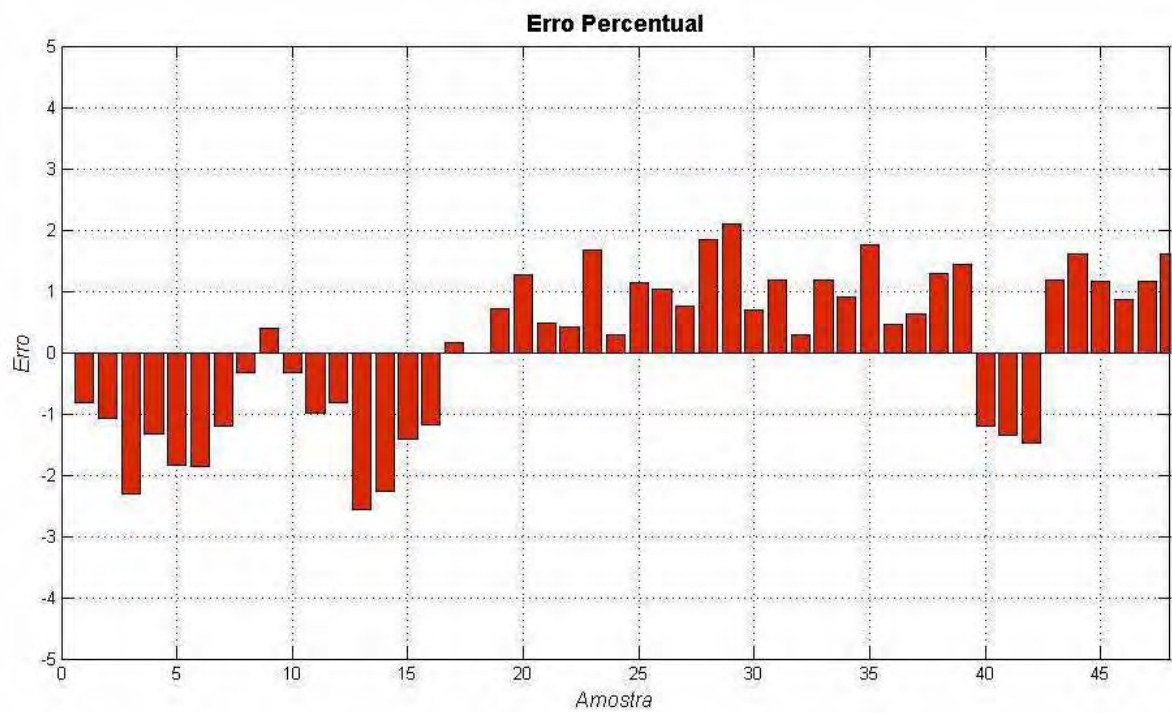
$$Erro\% = 100 \left[\frac{C^{Real}(n) - C^{Previsto}(n)}{C^{Real}(n)} \right] \quad (9)$$

Figura 14 – Previsão global 08/01/2008.



Fonte: da própria autora.

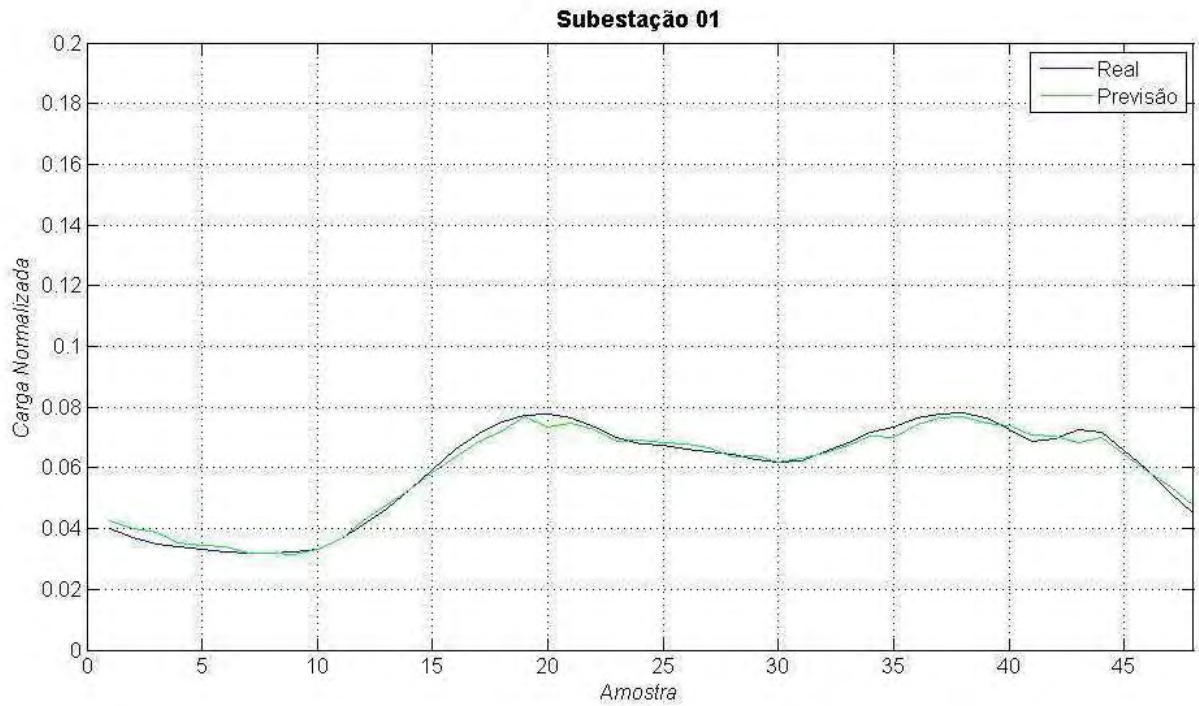
Figura 15 – Erro percentual da previsão global.



Fonte: da própria autora.

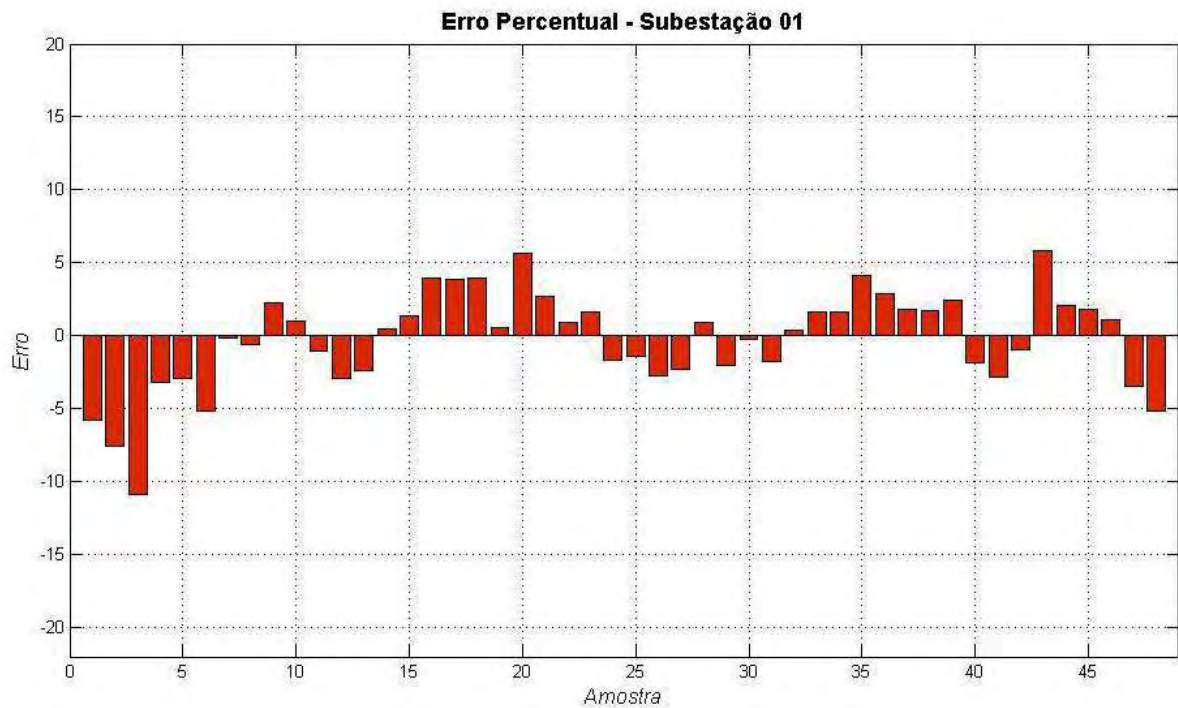
Nas Figuras 16 a 33 podem ser observadas as previsões locais e o erro percentual por subestação pelo sistema modelado utilizando o deslocamento de janela de tamanho igual a três.

Figura 16 – Previsão subestação 01 – 08/01/2009.



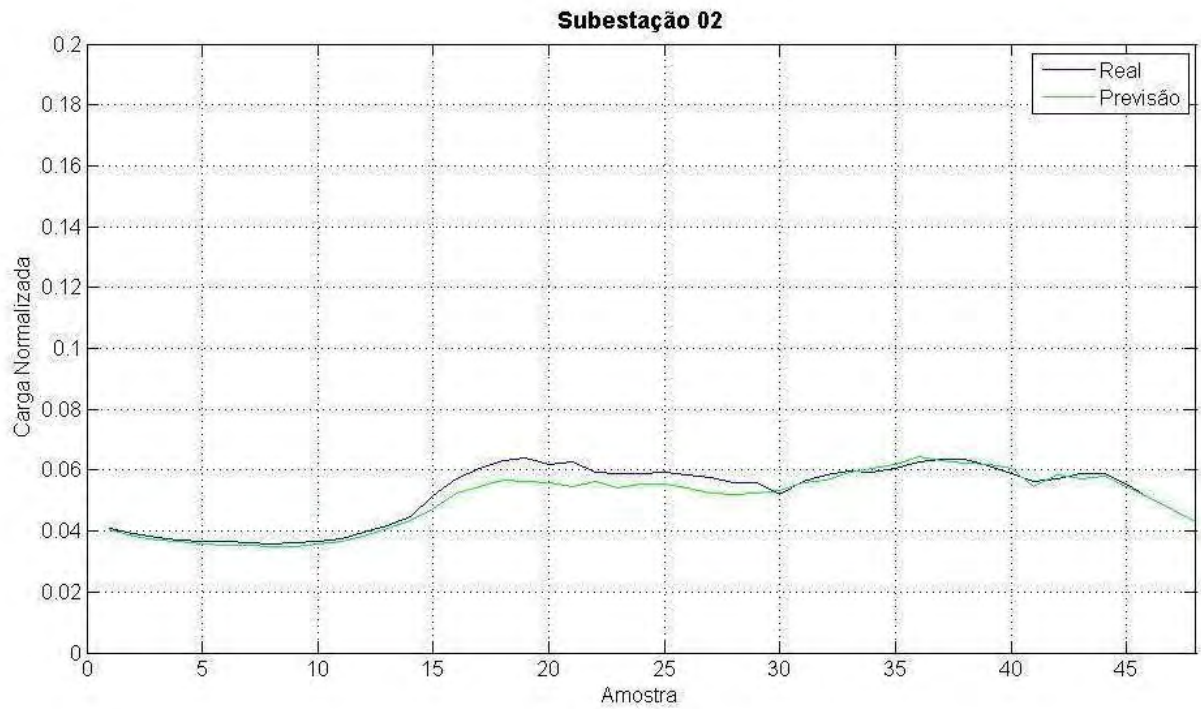
Fonte: da própria autora.

Figura 17 – Erro Percentual Subestação 01 – 08/01/2009.



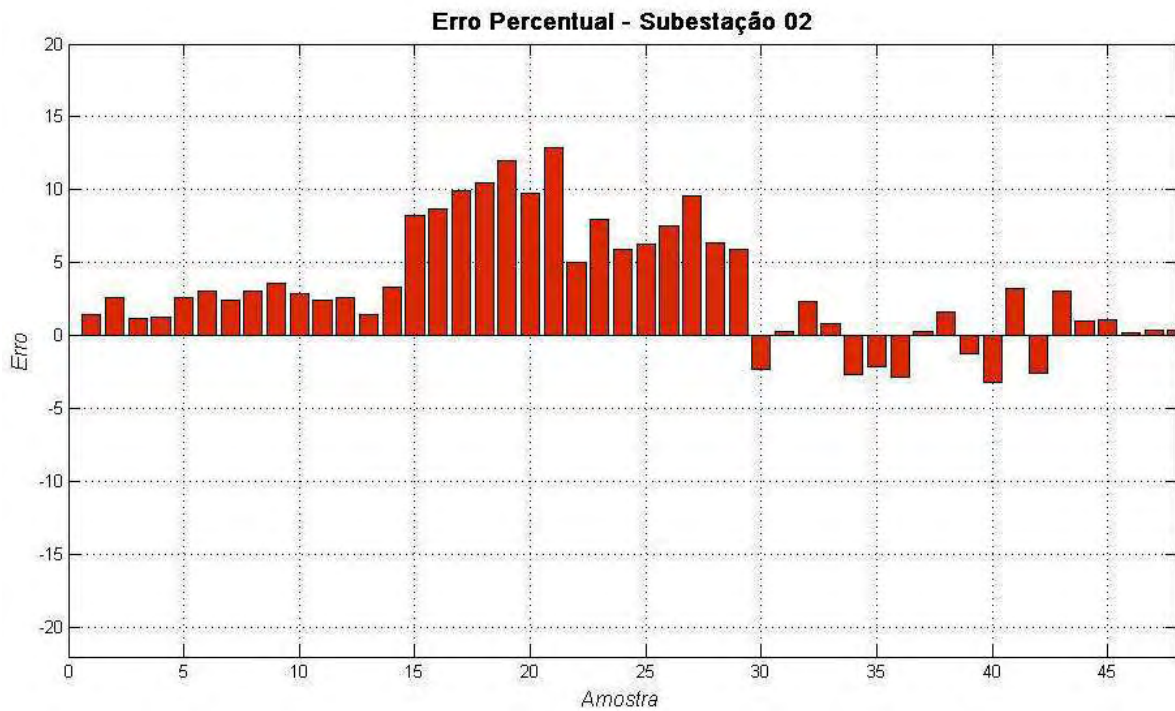
Fonte: da própria autora.

Figura 18 – Previsão Subestação 02 – 08/01/2009.



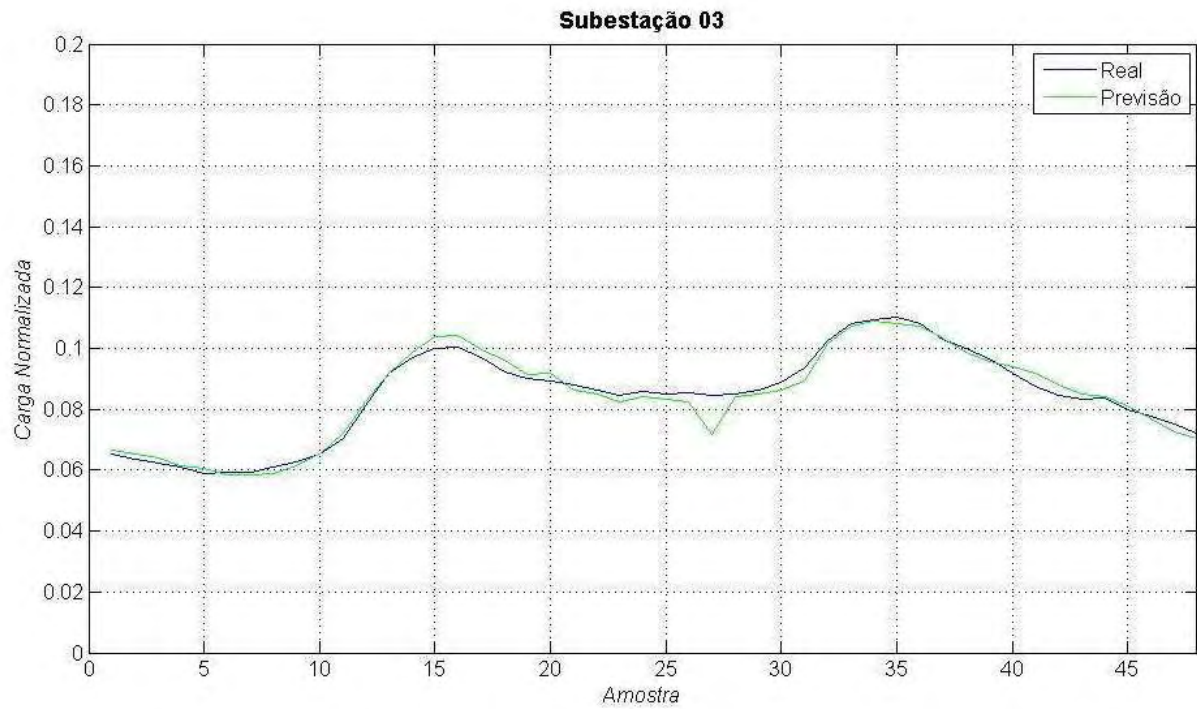
Fonte: da própria autora.

Figura 19 – Erro Percentual Subestação 02 – 08/01/2009.



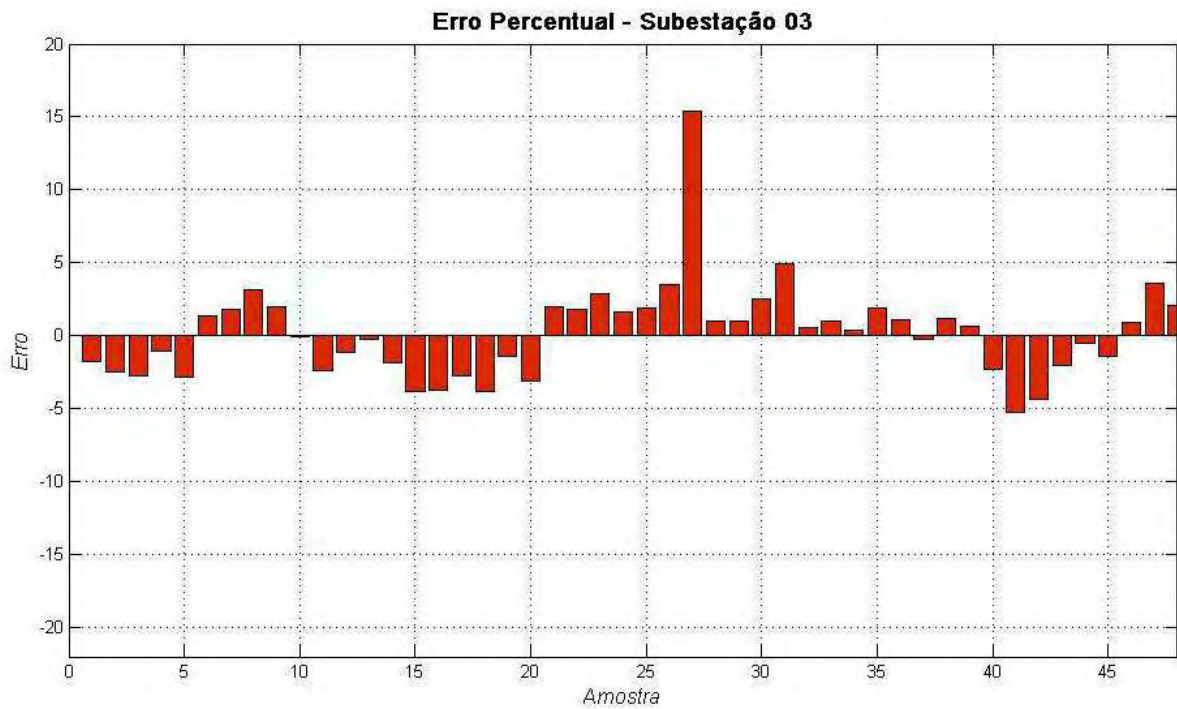
Fonte: da própria autora.

Figura 20 – Previsão subestação 03 – 08/01/2009.



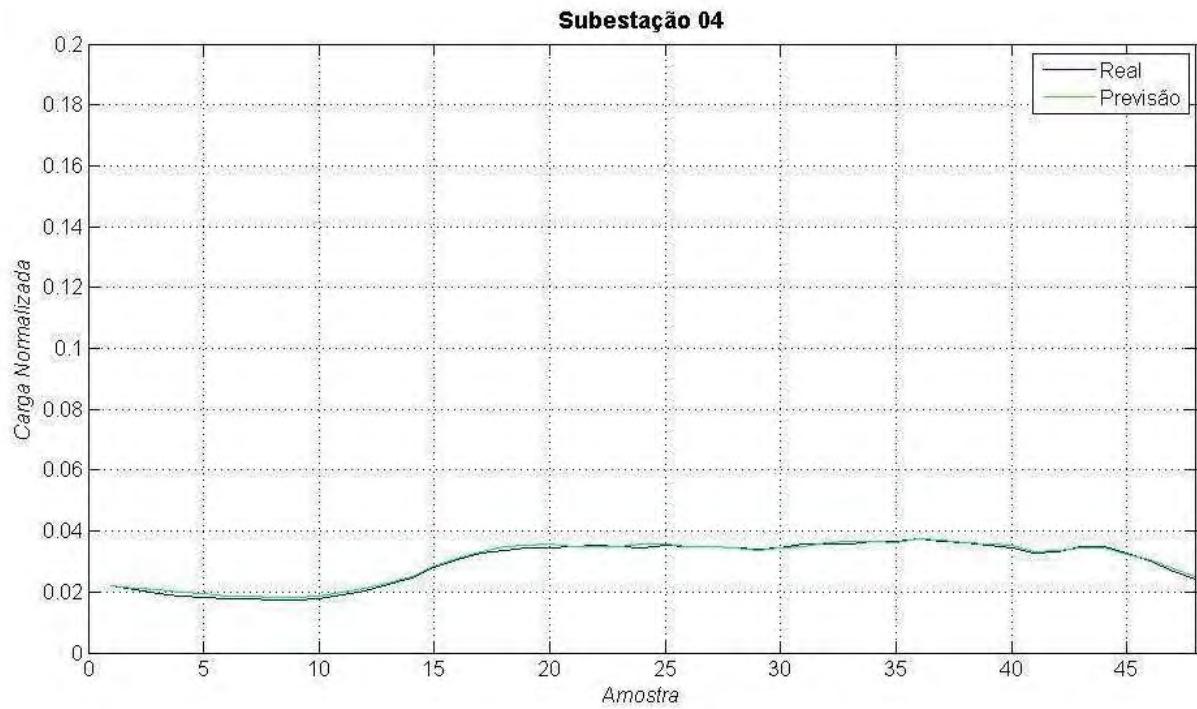
Fonte: da própria autora.

Figura 21 – Erro Percentual Subestação 03 – 08/01/2009.



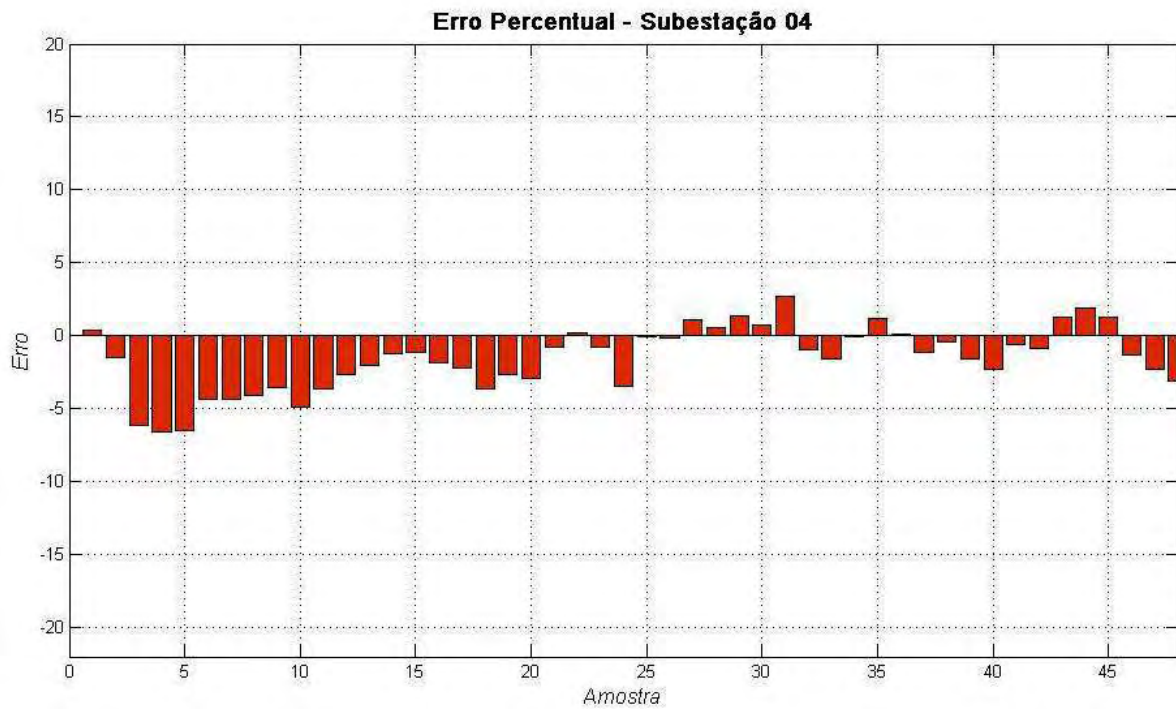
Fonte: da própria autora.

Figura 22 – Previsão subestação 04 – 08/01/2009.




Fonte: da própria autora.

Figura 23 – Erro Percentual Subestação 04 – 08/01/2009.




Fonte: da própria autora.

Figura 24 – Previsão subestação 05 – 08/01/2009.



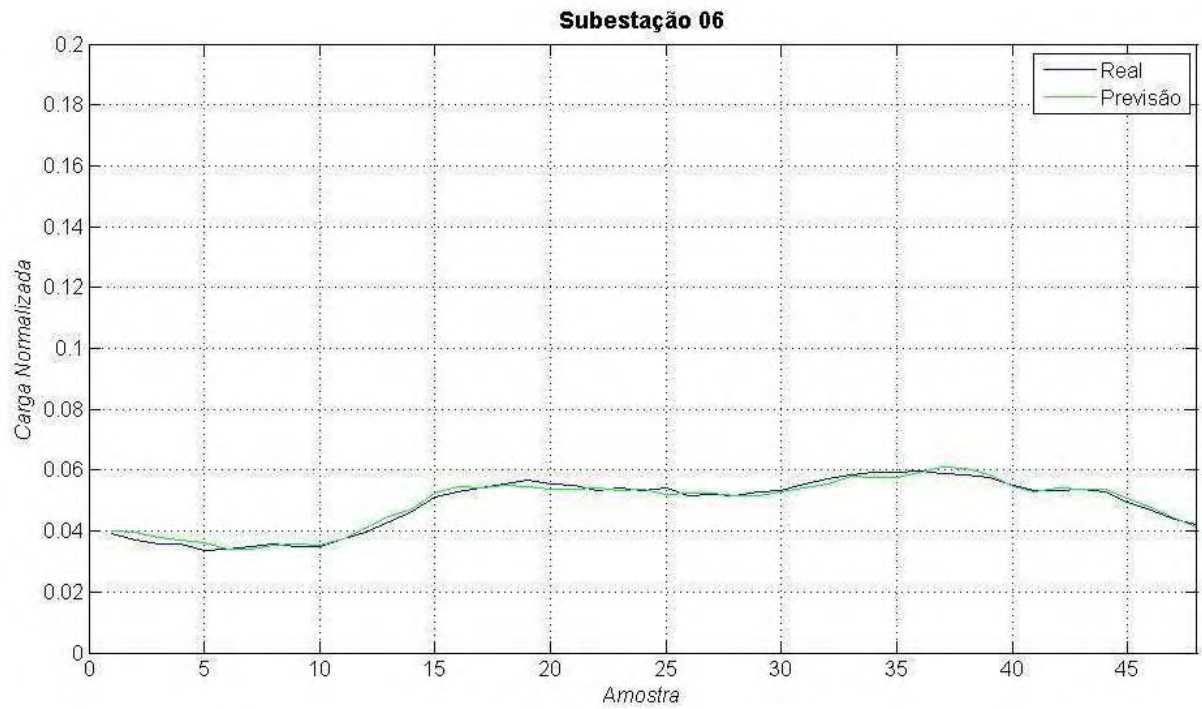
Fonte: da própria autora.

Figura 25 – Erro Percentual Subestação 05 – 08/01/2009.




Fonte: da própria autora.

Figura 26 – Previsão subestação 06 – 08/01/2009.




Fonte: da própria autora.

Figura 27 – Erro Percentual Subestação 06 – 08/01/2009.



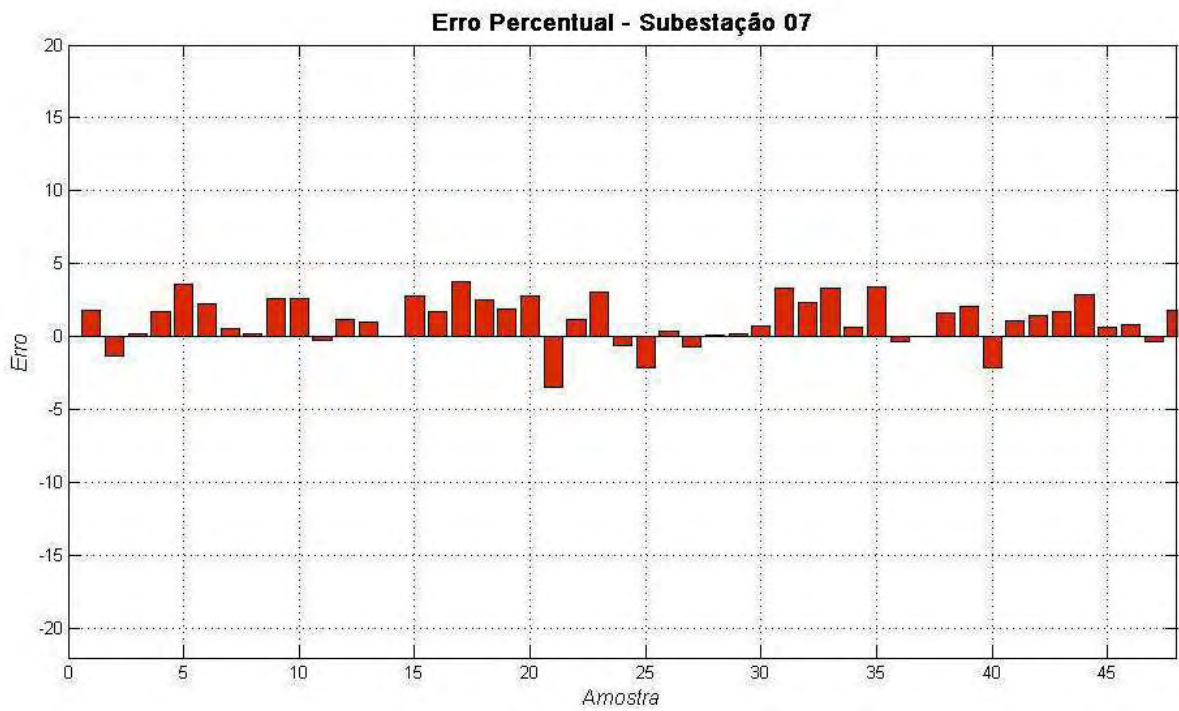
Fonte: da própria autora.

Figura 28 – Previsão subestação 07 – 08/01/2009.




Fonte: da própria autora.

Figura 29 – Erro Percentual Subestação 07 – 08/01/2009.



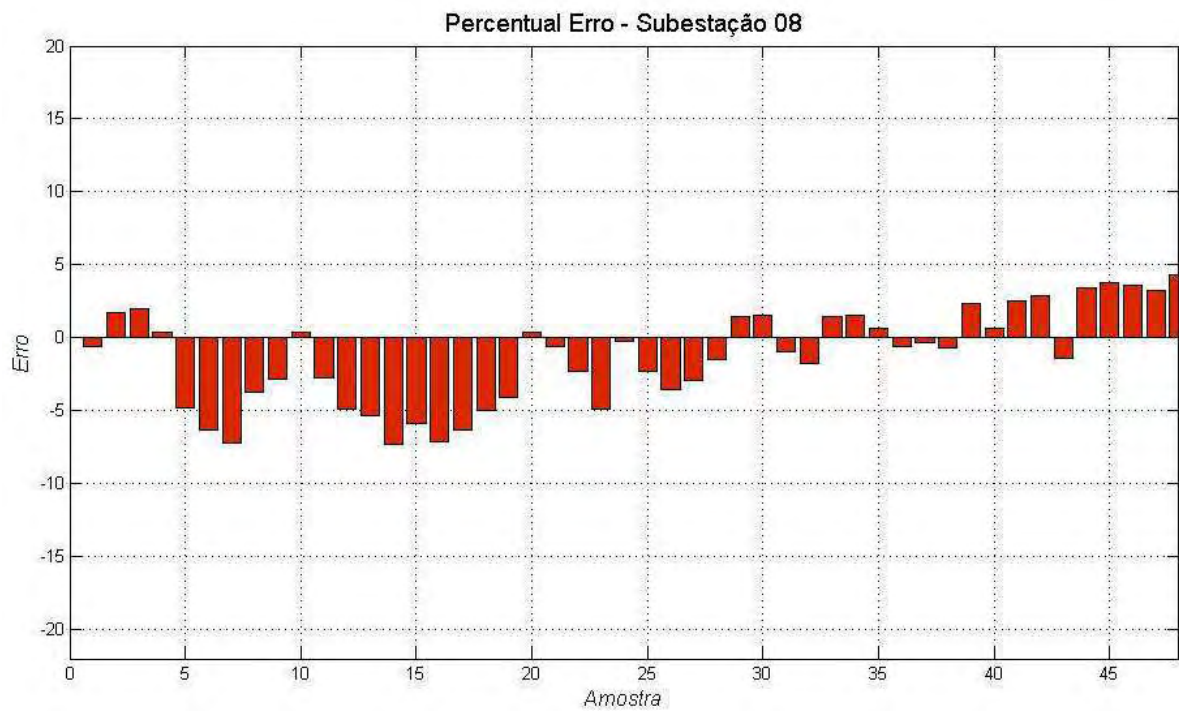
Fonte: da própria autora.

Figura 30 – Previsão subestação 08 – 08/01/2009.




Fonte: da própria autora.

Figura 31 – Erro Percentual Subestação 08 – 08/01/2009.




Fonte: da própria autora.

Figura 32 – Previsão subestação 09 – 08/01/2009.



Fonte: da própria autora.

Figura 33 – Erro Percentual Subestação 09 – 08/01/2009.




Fonte: da própria autora.

Na Figura 34, apresenta-se uma comparação de MAPEs utilizando duas, três e quatro janelas para treinamento e previsão da carga global e carga local das nove subestações. O tamanho de janela que melhor apresentou resultados de MAPE foi com três janelas. Porém, para previsão global os valores de MAPE foram semelhantes para os três tipos de deslocamento de janela.

O MAPE da previsão local da subestação 9 ainda apresenta valor elevado, um estudo que poderia ser realizado para contribuir para melhoria da previsão dessa subestação é incluir outros tipos de informações procedentes na entrada de treinamento e previsão da rede neural, por exemplo, informações sobre temperatura e tipo de consumidor (industrial, residencial, etc.).

Figura 34 – Comparação de MAPES para os três tipos de deslocamento de janela.



Fonte: da própria autora.

Na Tabela 3, mostra-se um comparativo de MAPEs entre a rede neural ART ARTMAP Fuzzy desta pesquisa com a rede neural GRNN-MR proposta por Nose-Filho (2010) para as nove subestações e também para global dos dias 08, 09, 10, 11, 12 e 26 de janeiro e dia 06 de fevereiro de 2009. Como pode ser observado que a rede proposta nesse trabalho melhorou os valores de MAPE e com isso as previsões globais e locais.

Tabela 3 – Comparativo Mapes GRNN-MR e ART ARTMAP Fuzzy.

SUBESTAÇÃO	08/01		09/01		10/01		11/01		12/01		26/01		06/02	
	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP	GRNN-MR	ART ARTMAP
1	4,87	2,62	4,07	1,67	3,14	1,71	3,03	1,87	2,36	2,00	3,62	1,93	11,3	1,84
2	10,2	4,01	10,95	3,37	9,72	3,22	9,06	2,09	3,14	2,86	3,41	2,61	5,31	1,73
3	4,16	2,33	3,64	3,07	3,31	2,49	5,02	3,65	3,77	2,26	3,19	3,37	6,8	2,00
4	4,06	2,08	3,67	2,71	1,77	1,82	3,05	1,32	1,63	1,56	1,88	2,24	3,39	1,30
5	3,34	1,77	2,57	1,80	3,20	1,14	2,92	1,81	2,87	1,24	1,63	1,92	2,59	1,59
6	3,65	2,18	2,25	1,73	4,89	2,09	4,64	2,59	7,40	4,77	3,04	2,19	1,92	2,10
7	4,11	1,62	8,02	2,39	9,64	2,67	5,35	1,66	6,93	2,24	5,81	3,17	6,72	2,01
8	6,86	2,84	3,64	2,30	6,35	2,09	5,97	2,27	4,21	2,19	7,56	4,85	6,85	2,27
9	9,08	8,08	9,56	7,43	10,46	10,68	8,38	8,31	6,51	7,76	7,12	6,97	4,39	2,84
Global	2,58	1,12	2,69	0,94	5,3	1,09	3,9	1,14	2,37	0,94	3,6	1,82	2,82	0,96

Fonte: da própria autora.

7 CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS

7.1 CONCLUSÕES

Se o mercado de energia possui um sistema para a previsão de carga, que execute a tarefa com o mínimo de erro e maior precisão, é possível maximizar os lucros e reduzir as perdas, utilizando estratégias de previsão apropriadas a cada região de planejamento. Os problemas em engenharia são dinâmicos e necessitam de ferramentas que consigam modelá-los.

Esta pesquisa visou o desenvolvimento de um sistema inteligente para a previsão global e para a previsão multimodal (envolvendo vários barramentos de interesse: subestações, alimentadores, etc.). Este sistema é constituído usando-se redes neurais da família ART Trata-se de uma rede neural ART-ARMAP-Fuzzy.

Um diferencial é que não existem muitas pesquisas que realizam previsões multimodais. A grande maioria realiza previsão global. O uso das redes neurais da família ART também é outro diferencial, pois quando se trata de redes neurais os pesquisadores utilizam a rede neural Perceptron Multicamadas (MLP) que, via de regra, não suporta processamento que envolve muitas informações.

O uso de redes neurais ART tem se mostrado eficaz para a resolução de problemas de previsão de cargas, apresentando uma grande capacidade de aprendizado e generalização, identificando e assimilando características das séries temporais, diferente dos procedimentos estatísticos utilizados na literatura que precisam de uma formulação teórica e modelagem prévia da carga.

Este trabalho apresentou o desenvolvimento de uma metodologia para previsão de carga, utilizando uma rede neural ART-ARTMAP Fuzzy, em vários pontos de um sistema de energia elétrica com tempo de processamento reduzido, comprovando que o modelo realiza a previsão de carga multinodal com rapidez e apresenta resultados compatíveis com a literatura especializada.

Os resultados foram analisados através da comparação dos valores reais da carga com valores previstos pela rede neural ART, utilizando o erro percentual absoluto médio. Foram realizados testes com três tamanhos diferentes de janelas para verificar se poderia

melhorar a previsão, principalmente para subestação nove, mas os valores encontrados por ambos foram muitos próximos.

O sistema, bem como o método desenvolvido foram validados como um bom sistema de previsão de cargas multinodal, apresentando resultados satisfatórios de forma rápida e precisa, mas como a subestação nove ainda apresenta erro percentual alto, pode-se tentar melhorar a previsão realizando acréscimo de algumas variáveis externas na entrada do módulo predictor FPCG, por exemplo, adicionar dados de temperatura e tipo do consumidor.

O uso da técnica de deslocamento de janela na entrada da rede neural mostra que o uso de uma janela de tamanho igual a três influencia positivamente nos resultados da previsão.

Observa-se que outros estudos podem ser realizados usando-se a metodologia proposta. Por exemplo, se a série temporal do FPCG for muito próxima de um valor constante, ou seguindo outra forma comportamental, pode-se melhor inferir sobre a composição da carga elétrica (residencial, comercial, industrial).

A previsão de carga multinodal proposta possui um tempo de execução um pouco superior à previsão global convencional (em função, evidentemente, do maior ou menor número de nós de interesse para a previsão), isto porque o tempo destinado à realização do conjunto das redes neurais modulares (previsão local) é bastante reduzido. Ressalta-se que o tempo para conclusão da previsão multinodal se aproxima ao tempo de execução da previsão global, à medida que forem exploradas outras arquiteturas neurais que, eventualmente, possam produzir resultados de forma mais rápida. Em todas as subestações a rede convergiu, com rapidez no tempo de processamento de treinamento e previsão por subestação, alcançando excelentes resultados de previsão e bons erros percentuais (com exceção da subestação 9).

A principal contribuição desta pesquisa foi desenvolver uma rede neural ART ARTMAP Fuzzy e aplicá-la na metodologia de previsão de carga multinodal, onde o sistema predictor realiza previsão de vários pontos da rede elétrica com tempo de processamento semelhante de uma previsão convencional (Global).

Para teste do sistema proposto, usou-se uma base de dados Centralised Dataset (CDS) fornecidos pela Electricity Commission da Nova Zelândia. A opção pelo uso desta base de dados foi em virtude da dificuldade na obtenção de bases similares (multimodais) no

Brasil. Ressalta-se que tais dados foram utilizados em outras pesquisas do grupo, cujos resultados tem sido bastante satisfatórios.

7.2 SUGESTÕES PARA TRABALHOS FUTUROS


Visando melhorar o desempenho do sistema previsor, propõe-se a implementação dos seguintes recursos:

1. Desenvolver um esquema visando à substituição de uma informação da carga, da base de dados, por um valor estimado pelo sistema previsor. Ou seja, durante o treinamento, após usado, por exemplo, um pequeno percentual da base de dados, um valor da carga considerado errôneo pode ser substituído pelo valor previsto pela rede neural, mesmo numa fase incipiente (fase inicial do treinamento). Este percentual pode ser estabelecido em consonância com os experimentos a ser realizados, ou seja, é um valor a ser fixado em função da experiência. Este processo é semelhante à rotina do treinamento continuado (MARCHIORI; SILVEIRA; LOTUFO; MINUSSI; LOPES, 2011);

2. explorar outros tipos de janelas, conforme ilustrado na Figura 35. Neste caso, a janela é composta pelos valores das cargas correspondente à hora h e p horas anteriores. Acrescentam-se, também, as cargas correspondentes à hora h da semana anterior e à hora h do mês anterior. Com esta estratégia, há maior perspectiva de melhoria da qualidade da previsão;

3. considerando-se a ilustração apresentada na Figura 6, observa-se a indicação, em cada módulo previsor local, de um bloco “entrada local”. Este dispositivo permite que se incluam outros tipos de informações procedentes, por exemplo, de dados fornecidos por satélite, sensores, outras informações gerais que possam contribuir para a melhoria da previsão. Estas informações são tratadas como uma técnica de fusão de sensores (ou de informações), a qual pode ser processada baseando-se, por exemplo, em redes neurais e na teoria de evidência de Dempster-Shafer (GONG, 2009).

Figura 35 – Previsão de carga via deslocamento da janela



Fonte: da própria autora.

REFERÊNCIAS

- AL-KANDARI, Ahmad M.; SOLIMAN, Soliman Abdel-hady.; EL-HAWARY, Mohammad E.. Fuzzy short-term electric load forecasting. **International Journal of Power and Energy Systems**, Oxford, v. 26, n. 2, p. 111-122, 2004.
- ALTRAN, Alessandra Bonato. **Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência**. 2010. 86 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.
- ANTUNES, Juliana Fonseca; MINUSSI, Carlos Roberto. Previsão de carga multinodal a curto prazo usando uma rede neural ART-ARTMAP-FUZZY. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS-BRACIS, 9., 2012, Curitiba. **Anais...** Curitiba: ENIA, 2012. Disponível em: <http://www.ppgia.pucpr.br/~enia/anais/enia/artigos/105368_2.pdf>. Acesso em: 15 abr. 2013.
- ANTUNES, Juliana Fonseca; ARAUJO, Nelcilenno Virgílio de Souza; MINUSSI, Carlos Roberto. Multinodal load forecasting using an ART-ARTMAP-fuzzy neural network and PSO strategy. In: IEEE PES POWERTECH, 2013, Grenoble. **Proceedings** Grenoble: PowerTech, 2013. (No prelo).
- BAO, Jie. **Short-term load forecasting based on Neural network and moving average**. Iowa: Technical report, Iowa State University, 2002. Disponível em: <www.cs.rpi.edu/~baojie/pub>. Acesso em: 3 maio 2010.
- BASSI, Danilo; OLIVARES, Oscar. Medium term electric load forecasting using TLFN neural networks. **International Journal of Computers, Communications & Control**, Romania, v. 1, n. 2, p. 23-32, 2006. Disponível em: <<http://www.journal.univagora.ro/download/pdf/34.pdf>>. Acesso em: 12 abr. 2013.
- BAUER, Peter; NOUAK, Stephan; WINKLER, Roman. **A brief course in fuzzy logic and fuzzy control**. [S.l.: s.n.], 1996. Disponível em: <<ftp://ftp.flll.uni-linz.ac.at/pub/info/>> . Acesso em: 24 abr. 2013.
- BENDER, Edward A. **Mathematical methods in artificial intelligence**. Piscataway: Wiley-IEEE Computer Society, 1996. 656 p.
- BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C. **Times series analysis: forecasting and control**. 4. ed. Hoboken: Wiley, 2008. 784 p.

BUNN, Derek. W. Forecasting loads and prices in competitive power markets. **Proceedings of the IEEE**, New York, v. 88, n. 2, p. 163-169, 2000. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=823996>>. Acesso em: 12 abr. 2013.

CANCELO, José Ramon; ESPASA, Antoni; GRAFE, Rosmarie. Forecasting the electricity load from one day to one week ahead for the spanish system operator. **International Journal of Forecasting**, Amsterdam, v. 24, n. 4, p. 588-602, 2008. Disponível em: < http://ac.els-cdn.com/S016920700800071X/1-s2.0-S016920700800071X-main.pdf?_tid=cd1c8b44-a5d0-11e2-809c-00000aab0f27&acdnat=1366032879_a8e86fd968f24c5869d2c02cf8953869>. Acesso em: 13 abr. 2013.

CARPENTER, Gail. A.; GROSSBERG, Stephen. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics and Image Processing**, New York, v. 37, p. 54-115, 1987a. Disponível em: < <http://www.cns.bu.edu/Profiles/Grossberg/CarGro1987CVGIP.pdf>>. Acesso em: 13 abr. 2013.

CARPENTER, Gail. A.; GROSSBERG, Stephen. ART2: stable self-organization of pattern recognition codes for analog input patterns. **Applied Optics**, New York, v. 26, p. 4919-4930, 1987b.

CARPENTER, Gail A.; GROSSBERG, Stephen.; REYNOLDS, John H. ARTMAP: supervised real-learning and classification of non-stationary data by a self-organizing neural network. **Artificial Neural Network**, v. 4, n.5, p. 565-588, 1991. Disponível em: < <http://cns.bu.edu/Profiles/Grossberg/CarGroRey1991NN.pdf>>. Acesso em: 12 abr. 2013.

CARPENTER, Gail A.; GROSSBERG, Stephen; ROSEN, David B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, New York, v. 4, n. 1, p. 759-771, 1991.

CARPENTER, Gail A.; GROSSBERG, Stephen. A Self-Organizing Neural Network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, New York, v. 30, n. 9, p. 38-49, 1992. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=15680>>. Acesso em: 12 abr. 2013.

CARPINTEIRO, Otávio A. S.; REIS, Agnaldo J. R.; SILVA, Alexandre P. A. A hierarchical neural model in short-term load forecasting. **Applied Computing**, New York, v. 4, n. 4, p. 405-412, 2004. Disponível em: < http://ac.els-cdn.com/S156849460400050X/1-s2.0-S156849460400050X-main.pdf?_tid=075ea370-a5cf-11e2-993d-00000aacb35f&acdnat=1366032117_40f81e49f82d2b5ad41a541be3b1ecb1>. Acesso em: 12 abr. 2013.

Centralized Dataset-CDS. **Electricity commission for the load dataset**. New Zealand:[s.n.], 2010.

CERQUEIRA, Eduardo O.; ANDRADE, João C.; POPPI, Ronei J.; MELLO, Cesar. Redes Neurais e suas aplicações em calibração multivariada. **Quím. Nova**. São Paulo, v. 24, n. 6, Dec. 2001. Disponível em: < http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-40422001000600025&lng=en&nrm=iso >. Acesso em: 2 maio 2013.

CHAABENE, Maher. Measurements based dynamic climate observer. **Solar Energy**, Kidlington, v. 82, n. 9, p. 763-771, 2008. Disponível em: < http://ac.els-cdn.com/S0038092X08000510/1-s2.0-S0038092X08000510-main.pdf?_tid=c211b942-a5ce-11e2-8ab9-00000aab0f27&acdnat=1366032001_e34e8579bea3ac29c31f089171541ec6 >. Acesso em: 12 abr. 2013.

CHANDRASHEKARA, Adiga S.; ANANTHAPADMANABHA, Tirupattur; KULKARNI, Arun D. A neuro-expert system for planning and load forecasting of distribution system. **Electrical Power and Energy Systems**, Guilford, n. 5, v. 21, p. 309-314, 1999. Disponível em: < http://ac.els-cdn.com/S014206159800057X/1-s2.0-S014206159800057X-main.pdf?_tid=924eecac-a5ce-11e2-b419-00000aab0f27&acdnat=1366031921_d5568669ba1791e2f7c7e219316a38b1 >. Acesso em: 12 abr. 2013.

CHEN, Chao-Shun; TZENG, Yenn-Minn; HWANG, Jong-Ching. The application of artificial neural networks to substation load forecasting. **Electric Power Systems Research**, Lausanne, v. 38, p. 153-160, 1996. Disponível em: <http://ac.els-cdn.com/S0378779696010772/1-s2.0-S0378779696010772-main.pdf?_tid=4c7b6ed0-a5ce-11e2-8ba8-00000aab0f02&acdnat=1366031804_2aab0002754894806143e77f6e83a129>. Acesso em: 12 abr. 2013.

COX, Earl. **The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems**. New York: AP Professional, 1994. 623 p.

DONG, Ruijun; PEDRYCZ, Witold. A granular time series approach to long-term forecasting and trend forecasting. **Physica A: Statistical Mechanics and its Applications**, New York, v. 387, n. 13, p. 3253-3270, 2008. Disponível em: < http://ac.els-cdn.com/S0378437108001040/1-s2.0-S0378437108001040-main.pdf?_tid=0d178db4-a5ce-11e2-b93a-00000aab0f6b&acdnat=1366031697_8c0ec8df430114594877ebb5b3387ca6 >. Acesso em: 12 abr. 2013.

DJUKANOVIC, Miodrag; RUZIC, Slobodan; BABIC, Borivoje; SOBAJIC, Dejan J.; PAO, Yoh-Han Han. A neural-net based short term load forecasting using moving window procedure. **Electrical Power & Energy Systems**, Guildford, v. 17, n. 6, p. 391-397, 1995. Disponível em: < http://ac.els-cdn.com/0142061594000093/1-s2.0-0142061594000093-main.pdf?_tid=cb12fd40-a5cd-11e2-a728-

0000aab0f01&acdnat=1366031587_26a306a424ebcb678249c4bee9016731>. Acesso em: 12 abr. 2013.

FIDALGO, José Nuno; LOPES, João Abel Peças. Load forecasting performance enhancement when facing anomalous events. **IEEE Transactions on Power Systems**, New York, v. 20, p. 408-415, 2005. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1388535&userType=inst>>. Acesso em: 14 jul. 2013.

GONG, Bing. An Algorithm of data fusion using artificial neural network and Dempster-Shafer evidence theory. In: IITA INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND SYSTEMS ENGINEERING – CASE, 2009, Zhangjiajie. **Proceedings...** Zhangjiajie: IEEE, 2009, p. 407 – 410. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5194478>>. Acesso em: 11 abr. 2013.

GONZALEZ-ROMERA, Eva; JARAMILLO-MORAN, Miguel A.; CARMONA-FERNANDEZ, Diego. Monthly electric energy demand forecasting with neural networks and Fourier series. **Energy Conversion and Management**, Oxford, v. 49, n. 11, p. 3135-3142, 2008. Disponível em: <http://ac.els-cdn.com/S0196890408002288/1-s2.0-S0196890408002288-main.pdf?_tid=6aab8b70-a5cd-11e2-97fd-0000aacb362&acdnat=1366031425_0490517b9718a17753c0f059cf0d3a98>. Acesso em: 12 abr. 2013.

GRANGER, Eric; HENNIGES, Philippe; SABOURIN, Robert; OLIVEIRA, Luiz. S. Supervised learning of fuzzy ARTMAP Neural Networks through Particle Swarm Optimization. **Journal of Pattern Recognition Research**, p. 27-60. 2007. Disponível em: <http://en.etsmtl.ca/ETS/media/ImagesETS/Labo/LIVIA/Publications/2007/Granger_jpr_2007.pdf>. Acesso em: 17 jul. 2013.

GROSS, George; GALIANA, Francisco D. Short-term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01458194>>. Acesso em: 12 abr. 2013.

GROSSBERG, Stephen. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976a.

GROSSBERG, Stephen. Adaptive pattern classification and universal recoding, II: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, New York, v. 23, n. 4, p. 187-202, 1976b.

GROSSBERG, Stephen. Competitive learning: from interactive activation to adaptive resonance. **Cognitive Science**, Norwood, v. 11, p. 23-63, 1987. Disponível em: <

http://techlab.bu.edu/files/resources/articles_cns/Gro1987CogSci.pdf>. Acesso em: 12 abr. 2013.

HAYKIN, Simon O. **Neural networks and learning machines**. 3. ed. New Jersey: Prentice-Hall, 2008. 936 p.

HEBB, Donald O. **The organization of behaviour**. New York: Wiley, 1949. 378 p.

HONG, Wei-Chiang. Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model. **Energy Conversion and Management**, Oxford, v. 50, n. 1, p. 105-117, 2009. Disponível em: < http://ac.els-cdn.com/S019689040800318X/1-s2.0-S019689040800318X-main.pdf?_tid=30da62f0-a5cc-11e2-946b-00000aacb362&acdnat=1366030898_6a53cf677e9d2c1ccd133ea56c73d926>. Acesso em: 12 abr. 2013.

HOPFIELD, John Joseph. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences**, Allahabad, v. 79, p. 2554-2558, 1982. Disponível em: <<http://www.pnas.org/content/79/8/2554.full.pdf+html> >. Acesso em: 23 abr. 2013.

HUANG, Ming-Yang.; CHEN, Chao-Shen; LIN, Chia-Hung. Innovative service restoration of distribution systems by considering short-term load forecasting of service zones. **Electrical Power and Energy Systems**, Guildford, v. 27, p. 417-427, 2005. Disponível em: < http://ac.els-cdn.com/S0142061505000360/1-s2.0-S0142061505000360-main.pdf?_tid=3de32b90-a5cb-11e2-a066-00000aab0f6c&acdnat=1366030497_a90748bf6bff5f125ee4bbd771e722a2>. Acesso em: 12 abr. 2013.

INOUE, Ynoue; MIYAZAKI, Kumiko. Technological innovation and diffusion of wind power in Japan. **Technological Forecasting and Social Change**, New York, v. 75, n. 8, p. 1303-1323, 2008. Disponível em: < http://ac.els-cdn.com/S0040162508000103/1-s2.0-S0040162508000103-main.pdf?_tid=090bcb8e-a5cb-11e2-825a-00000aacb35f&acdnat=1366030402_6a3fc26252137eac17f6d8e27246647>. Acesso em: 12 abr. 2013.

KENNEDY, James; EBERHART, Russel. Particle swarm intelligence. Int. Conf. on Neural Network, Piscataway, **Proceedings ...** p. 1942-1948, 1995. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=488968>>. Acesso em: 17 jul. 2013.

KERMANSHAHI, Bahman; IWAMIYA, Hiroshi. Up to year 2020 load forecasting using neural Nets. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 24, n. 9, p. 789-797, 2002. Disponível em: < <http://ac.els-cdn.com/S0142061501000862/1-s2.0->

S0142061501000862-main.pdf?_tid=8b8b0e36-a5ca-11e2-81c8-00000aacb35f&acdnat=1366030192_c08c1b9b22090c3ad4dd96b9aff75133>. Acesso em: 14 abr. 2013.

KIARTZIS, Spyros J.; ZOUMAS, Christoforos E.; BAKIRTZIS, Anastasios G.; PETRIDIS, Vasilios. Data pre-processing for short-term load forecasting in an autonomous power system using artificial neural networks. In; INTERNATIONAL CONFERENCE ON ELECTRONICS, CIRCUITS, AND SYSTEMS - ICECS, 3, 1996, Rodos. **Proceedings ...** Rodos: IEEE, 1996. v. 2, p. 1021-1024.

KOHONEN, Teuvo. Correlation matrix memories. **IEEE Transactions on Computers**, New York, v. 21, n. 4, p. 353-359, 1972. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5008975>>. Acesso em: 23 abr. 2013.

KROSE, Ben; SMAGT, Patrick van der. **An introduction to neural networks**. 8 ed. Amsterdam: University of Amsterdam, 1996. 135 p. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.18.493>>. Acesso em: 23 abr. 2013.

LEFEBVRE, Serge; DESBIENS, Charles. Residential load modeling for predicting distribution transformer load behavior, feeder load and cold load pickup. **Electrical Power and Energy Systems**, Guildford, v. 24, p. 285-293, 2002. Disponível em: <http://ac.els-cdn.com/S0142061501000400/1-s2.0-S0142061501000400-main.pdf?_tid=5dcaef7a-a5ca-11e2-abcd-00000aab0f6c&acdnat=1366030115_eada2845dcdd3eb50df8aec2a6312d1e>. Acesso em: 14 abr. 2013.

LOPES, Mara Lúcia Martins. **Desenvolvimento de redes neurais artificiais para previsão de cargas elétricas de sistemas de energia elétrica**. 2005. 149 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

LOPES, Mara Lúcia Martins; MINUSSI, Carlos Roberto; LOTUFO, Anna Diva Plasencia. Electric load forecasting using a fuzzy ART&ARTMAP neural network. **Applied Computing**, New York, v. 5, n. 2, p. 235-244, 2005. Disponível em: <http://ac.els-cdn.com/S1568494604000717/1-s2.0-S1568494604000717-main.pdf?_tid=31932c90-a5c2-11e2-9627-00000aacb360&acdnat=1366026605_f02410f0f4ff57a1a4c67ee3ed0c2712>. Acesso em: 14 abr. 2013.

MARCHIORI, Sandra Cristina; SILVEIRA, Maria do Carmo Gomes; LOTUFO, Anna Diva Plasencia; MINUSSI, Carlos Roberto; LOPES, Mara Lúcia Martins. Neural network based an adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. **Applied Soft Computing**, New York, v. 11, n. 1, p. 706-715, 2011. Disponível em: <http://ac.els-cdn.com/S1568494609002890/1-s2.0-S1568494609002890-main.pdf?_tid=e42d5958-a5c1-11e2-90ee-

0000aab0f6b&acdnat=1366026475_81ae40e93729cb7bf81640f04fda74e8>. Acesso em: 14 abr. 2013.

McCULLOCH, Warren; PITTS, Walter A. A logical calculus of the ideas imminent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v. 5, p. 115-133, 1943.

METAXIOTIS, Kostas; KAGIANNAS, Argyris; ASKOUNIS, Dimitri; PSARRAS, John. Artificial intelligence in short term electric load forecasting: A state-of-the-art survey for the researcher. **Energy Conversion and Management**, Oxford, v. 44, n. 9, p. 1525-1534, 2003. Disponível em: < http://ac.els-cdn.com/S0196890402001486/1-s2.0-S0196890402001486-main.pdf?_tid=77b8b844-a5c1-11e2-bb04-00000aab0f27&acdnat=1366026293_bb7bbf2838fc79cd6927ec8359873b8c>. Acesso em: 14 abr. 2013.

MIRANDA, Vladimiro; MONTEIRO, Cláudio. Fuzzy inference applied to spatial load forecasting. In: INTERNATIONAL CONFERENCE ON ELECTRIC POWER ENGINEERING, IEEE POWER TECH CONFERENCE, 1999, Budapest. **Proceedings ...** Budapest: IEEE, 1999. 6 p. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=826435>>. Acesso em: 15 mar. 2013.

MOTA, Lia Toledo Moreira; MOTA, Alexandre Assis. Load modeling at electric power distribution substations using dynamic load parameters estimation. **Electrical Power and Energy Systems**, Guildford, v. 26, p. 805-811, 2005. Disponível em: < http://ac.els-cdn.com/S0142061504000924/1-s2.0-S0142061504000924-main.pdf?_tid=40a764fe-a5c1-11e2-946b-00000aacb362&acdnat=1366026200_d60681aaf0c7d3cdac2506a64436d>. Acesso em: 14 abr. 2013.

MURTO, Pauli. **Neural network models for short-term load forecasting**. 1998. Thesis (Master) - Department of Engineering Physics and Mathematics, Helsinki University of Technology, Helsinki, 1998.

NAHI, Saeid. Load forecasting on special days & holidays in power distribution substation using neural & fuzzy networks. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE FOR MODELLING CONTROL AND AUTOMATION, CIMCA, 6., 2006, Sydney. **Proceedings...** Sydney: IEEE, 2006. p. 118. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4052749>>. Acesso em: 12 abr. 2013.

NIU, Dongxiao; LI, Jinchao; LI, Jinying.; LIU, Da. Middle-long power load forecasting based on particle swarm optimization. **Computers & Mathematics with Applications**, New York, v. 57, p. 1883-1889, 2009. Disponível em: <<http://dl.acm.org/citation.cfm?id=1537413>>. Acesso em: 14 abr. 2013.

NOSE-FILHO, Kenji; ARAÚJO, Klayton A. M.; MAEDA, Jorge L. Y.; LOTUFO, Anna Diva Plasencia. Previsão de cargas elétricas utilizando diferentes arquiteturas de redes neurais artificiais com o auxílio das toolboxes do MATLAB. In: LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION, CLAGTEE, 8., 2009, Ubatuba. **Proceedings..** Ubatuba: Unesp/FEG, 2009.

NOSE-FILHO, Kenji. **Previsão de carga multinodal utilizando redes neurais de regressão generalizada.** 2010. 81f. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

NOSE-FILHO, Kenji; LOTUFO, Anna Diva Plasencia; MINUSSI, Carlos Roberto. Short-term multinodal load forecasting using a modified general regression neural network. **IEEE Transaction on Power Delivery**, New York, v. 26, n. 4, p. 2862-2869. 2011a. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6026243>>. Acesso em: 13 abr. 2013.

NOSE-FILHO, Kenji; LOTUFO, Anna Diva Plasencia; MINUSSI, Carlos Roberto. Short-term multinodal load forecasting in distribution systems using general regression neural networks. In: IEEE PES POWER TECH, 2011, Trondheim. **Proceedings of the...** Trondheim: IEEE, 2011b. p. 1-7. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6019432>>. Acesso em: 12 abr. 2013.

NOSE-FILHO, Kenji; LOTUFO, Anna Diva Plasencia; MINUSSI, Carlos Roberto. Preprocessing data for short-term load forecasting with a general regression neural network and a moving average filter. In: IEEE PES POWER TECH, 2011, Trondheim. **Proceedings of the...** Trondheim: IEEE, 2011c. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=06019428>>. Acesso em: 13 abr. 2013.

O'DONOVAN, Thomas M. **Short term forecasting:** an introduction to the box-jenkins approach. New York: John Wiley & Sons, 1983.

PARK, Dong Chd; EL-SHARKAWI, Mohammed A.; MARKS II, Robert J. Electric load forecasting using an artificial neural network. **IEEE Transaction on Power System**, New York, v. 6, n. 2, p. 442-449, 1991. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=76685>>. Acesso em: 13 abr. 2013.

PINO, Raul; PARRENO, José; GOMEZ, Alberto; PRIORE, Paolo. Forecasting next-day price of electricity in spanish energy market using artificial neural networks. **Engineering Applications of Artificial Intelligence**, New York, v. 21, p. 53-62, 2008. Disponível em: < http://ac.els-cdn.com/S0952197607000097/1-s2.0-S0952197607000097-main.pdf?_tid=878ac27c-a5c0-11e2-a3a9-00000aab0f01&acdnt=1366025890_aea33e19d2db39736da6daadfdb167a4>. Acesso em: 13 abr. 2013.

ROQUES, Fabien A. Technology choices for new entrants in liberalized markets: the value of operating flexibility and contractual arrangements. **Utilities Policy**, Guildford, v. 16, n. 4, p. 245-253, 2008.

SALGADO, Ricardo Menezes; OHISHI, Takaaki; BALLINI, Rosangela. A short-term bus load forecasting system. **International Journal of Computer Information Systems and Industrial Management Applications**, New York, v. 3, p. 336-346, 2011. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5600075>>. Acesso em: 13 abr. 2013.

SANO, Tsuneyo; TEZUCA, Itsuko; FUKUDA, Yoshihiro. The load forecasting technology in the electric power distribution system. **IEEE Transactions on Power and Energy**, New York, v. 124, n. 6, p. 824-834, 2004.

SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SIMÕES, Marcelo Godoy; SHAW, Ian S. **Controle e Modelagem Fuzzy**. São Paulo: Edgar Blücher, 2007. 200 p.

SWARUP, K. Shanti; SATISH, Babu. Integrated ANN approach to forecast load. **IEEE Computer Applications in Power**, New York, v. 15, n. 1, p. 46-51, 2002. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=993760&userType=inst>>. Acesso em: 11 abr. 2013.

SRINIVASAN, Dipiti.; TAN, Swee Sien; CHANG, Che-Sau Sau; CHAN, Eng Kiat. Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting. **IEEE Proceedings Generation, Transmission and Distribution**, New York, v. 145, n. 6, p. 687-692, 1998. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=749170>>. Acesso em: 11 abr. 2013.

TANG, Zayong; ALMEIDA, Chrys; FISCHWICH, Paul A. **Time series forecasting using neural network vs. Box-Jenkins methodology: simulation councies**. San Diego: Transactions of the Society for Modeling and Simulation International, San Diego, 1991. p. 303-310.

TOPALLI, Ayca Kumluca; ERKMEN, Ismet; TOPALLI, Ihsan. Intelligent short-term load forecasting in Turkey. **Electrical Power and Energy Systems**, Guildford, v. 28, n. 7, p. 437-447, 2006. Disponível em: < http://ac.els-cdn.com/S0142061506000512/1-s2.0-S0142061506000512-main.pdf?_tid=d2a89122-a5bf-11e2-a066-

0000aab0f6c&acdnat=1366025586_e39cb1ec15e45bfe4687b4a0c1f7675f>. Acesso em: 13 abr. 2013.

ULAGAMMAI, Muthu; VENKATESH, Paramasivam; KANNAN, Sriraman.; PADHY, Narayana Prasad. Application of bacterial foraging technique trained artificial and wavelet neural networks in load forecasting. **Neurocomputing**, Cambridge, v. 70, n. 16-18, p. 2659-2667, 2007. Disponível em: < http://ac.els-cdn.com/S0925231207000926/1-s2.0-S0925231207000926-main.pdf?_tid=868c463c-a3b0-11e2-9965-00000aab0f26&acdnat=1365799114_6cc594169e9c2cad4943a94a9317af39>. Acesso em: 11 abr. 2013.

VAHIDINASAB, Vahid; JADID, Shahram B; KAZEMI, Ahad. Day-ahead price forecasting in restructured power systems using artificial neural networks. **Electric Power Systems Research**, Guildford, v. 78, n. 8, p. 1332-1342, 2008. Disponível em: < http://ac.els-cdn.com/S0378779607002362/1-s2.0-S0378779607002362-main.pdf?_tid=53e6f608-a5bf-11e2-9833-00000aacb35e&acdnat=1366025374_91c81c010d15fcf0deec30914f951e83>. Acesso em: 13 abr. 2013.

WANG, Xin; HATZIARGYRIOU, Nicholas; TSOUKALAS, Lefteri H. A new methodology for nodal load forecasting in deregulated power systems. **IEEE Power Engineering Review**, New York, v. 22, n. 5, p. 48-51, 2002. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=999661&userType=inst>>. Acesso em: 13 abr. 2013.

WANG, Bo; TAI, Neng-Ling; ZHAI, Hai-Qing; YE, Jian; ZHU, Jia-Dong; QI, Liang-Bo. A new ARMAX model based on evolutionary algorithm and particle swarm optimization for short-term load forecasting. **Electric Power Systems Research**, Guildford, v. 78, n. 10, p. 1679-1685, 2008. Disponível em: < http://ac.els-cdn.com/S0378779608000709/1-s2.0-S0378779608000709-main.pdf?_tid=a48cd9c0-a5be-11e2-b418-00000aab0f27&acdnat=1366025080_448ba50aeaff23f71a6d6dd9e9a73992>. Acesso em: 14 abr. 2013.

WASSERMAN, Philip D. **Neural computing theory and practice**. New York: Van Nostrand Reinhold, 1989. 230 p.

WERBOS, Paul John. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. Thesis (Doctor – PHD)- Harvard University, Harvard, 1974.

WIDROW, Bernard; HOFF, Marcian E. Adaptive switching circuits. **Western Electronic Show and Convention – Convention Record**, v. 4, p. 96-104, New York, 1960. Disponível em: <<http://www-isl.stanford.edu/~widrow/papers/c1960adaptiveswitching.pdf>>. Acesso em: 23 abr. 2013.

WILLIS, H. Lee. **Spatial electric load forecasting**. 2. ed. New York: Marcel Dekker , 2002. 748 p.

WOLFRAM, Stephen. **A new kind of science**. 5. ed. Champaign: Wolfram Media, 2003. 2003. 1197 p.

WU, Lizeng; YUAN, JinSha; ZHU, Yongli. **Mis-based long term distribution load forecasting system**. In: INTERNATIONAL CONFERENCE ON ADVANCES IN POWER SYSTEM CONTROL, OPERATION AND MANAGEMENT, ASDCOM, 6., 2003, Hong Kong. **Proceedings...** New York: IEEE, 2003. v. 2, p. 880 – 883. (Conference Publication, 497). Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1351773>>. Acesso em: 14 abr. 2013.

XIAO, Zhi; YE, Shi-Jie; ZHONG, Bo; SUN, Cai-Xin. BP Neural network with rough set for short term load forecasting. **Expert Systems with Applications**, New York, v. 36, n. 1, p. 273-279, 2009. Disponível em: <http://ac.els-cdn.com/S095741740700423X/1-s2.0-S095741740700423X-main.pdf?_tid=a99bbdba-a5bd-11e2-956e-00000aacb35e&acdnat=1366024659_84b953cc69f1ace9c6f6eadb9b40d4df>. Acesso em: 14 abr. 2013.

YALCINOZ, Tankut; EMINOGLU, Ulas. Short term and medium term power distribution load forecasting by neural networks. **Energy Conversion and Management**, Oxford, v. 46, p. 1393-1405, 2005.

ZADEH, Lofti A. Fuzzy sets. **Information and Control**. New York, v. 8, p. 338-353, 1965. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S00199586590241X>>. Acesso em: 24 abr. 2013.

APÊNDICE A

PUBLICAÇÕES

ANTUNES, Juliana Fonseca; ARAUJO, Nelcileo Virgílio de Souza; MINUSSI, Carlos Roberto. Multinodal load forecasting using an ART-ARTMAP-fuzzy neural network and PSO strategy. In: IEEE PES POWERTECH, 2013, Grenoble. **Proceedings....** Grenoble: PowerTech, 2013.

ANTUNES, Juliana Fonseca; MINUSSI, Carlos Roberto. Previsão de carga multinodal a curto prazo usando uma rede neural ART-ARTMAP-FUZZY. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS - BRACIS 2012, 9, 2012, Curitiba. **Anais...** Curitiba: BRACIS, 2012. Disponível em: <http://www.ppgia.pucpr.br/~enia/anais/enia/artigos/105368_2.pdf>. Acesso em: 15 abr. 2013.

APÊNDICE B

REDES NEURAIS ARTIFICIAIS

A capacidade de implementar computacionalmente versões simplificadas de neurônios biológicos deu origem a uma especialidade da inteligência artificial, conhecida como redes neurais artificiais (HAYKIN, 2008).

Redes neurais artificiais se assemelham as concepções biológicas do mecanismo de funcionamento do cérebro humano, munido de complicados circuitos neurais cerebrais que constam de diferentes conexões entre seus neurônios (sinapses), interagindo entre si de modo a ter comportamento inteligente e como resultado possui a capacidade de aprender e se adaptar quando submetidas a treinamento, adquirindo conhecimento através da experiência.

A estrutura neural de processamento e conexão foi modelada matematicamente permitindo a elaboração de algoritmos computacionais que simulam de forma simplificada o neurônio (CERQUEIRA et al., 2001).

NEURÔNIO BIOLÓGICO

O sistema nervoso do ser humano é formado por um conjunto extremamente complexo de neurônios, responsável pelos fenômenos conhecidos como pensamento, emoção e cognição, além da execução das funções sensores-motoras e autônomas (WASSERMAN, 1989). Neurônio recebe e envia informações de muitos outros neurônios e para várias partes do organismo, além de armazenar estas informações.

Os neurônios estão conectados uns aos outros através de sinapses, e juntos, formam uma grande rede, chamada Rede Neural (HAYKIN, 2008).

Conforme mostrado na Figura 36, os neurônios biológicos são formados pelas seguintes partes (HAYKIN, 2008):


Corpo celular (sôma do idioma grego): parte central do neurônio responsável pela geração e recepção dos impulsos nervosos (HAYKIN, 2008).

Dendritos: tem a função de receber as informações, ou impulsos nervosos de outros neurônios e conduzi-las ao corpo celular (HAYKIN, 2008).

Axônios: tem a função de conduzir sinais, processados pelo corpo celular, para os demais neurônios. Distingue-se de um dendrito pelo seu tamanho. Axônio divide-se em vários ramos (dendritos), que se interconectam com os demais neurônios através das sinapses (HAYKIN, 2008).

Sinapse: é o ponto de contato entre a terminação axônica de um neurônio e o dendrito do outro (junção axônio/dendrito). Funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios (HAYKIN, 2008).

Figura 36 – Neurônio biológico



Fonte: Wasserman (1989).

NEURÔNIO ARTIFICIAL

O elemento básico que forma uma rede neural artificial é o neurônio artificial baseado no funcionamento de um neurônio biológico, conhecido também por nó ou elemento processador. Uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (HAYKIN, 2008).

As RNA apresentam diversas características em comum com o sistema nervoso:

- ✓ Processamento das informações ocorre nos neurônios artificiais;
- ✓ Neurônios estão interconectados gerando redes de neurônios, ou redes neurais;
- ✓ Os sinais (informações) são transmitidos entre neurônios através de conexões ou sinapses;
- ✓ A eficiência de uma sinapse, representada por um peso associado, corresponde à informação armazenada pelo neurônio;

✓ O conhecimento é adquirido do ambiente através de um processo de aprendizagem que é, basicamente, responsável por adaptar os pesos das conexões aos estímulos recebidos do ambiente.

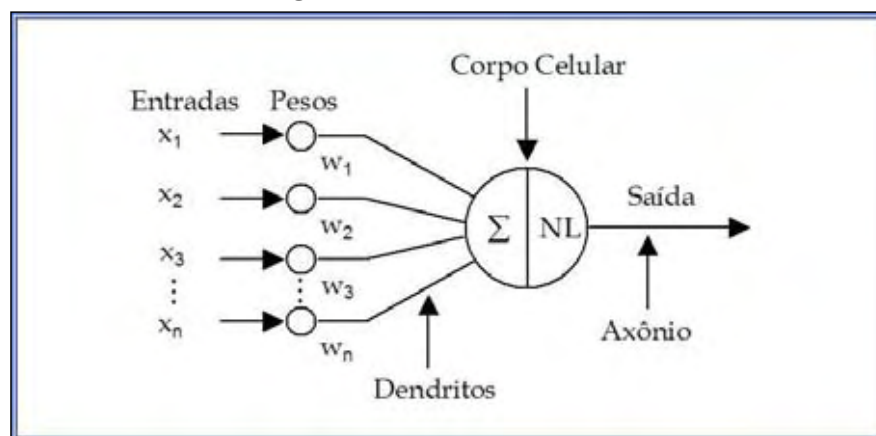
Segundo Wasserman (1989) algumas características do neurônio artificial são:

- **Processamento paralelo maciço:** Utiliza treinamento para armazenar conhecimento.
- **Conexões sinápticas:** interligações entre neurônios para armazenar informações.
- **Capacidade de generalização:** fornecer em tempo real saídas com precisão razoável para entradas que não participaram da fase de treinamento.

O modelo apresentado na Figura 37 foi proposto por McCulloch e Pitts (McCULLOCH; PITTS, 1943) é uma simplificação do que se sabia então a respeito do neurônio biológico. Segundo interpretação de McCulloch e Pitts (1943) o neurônio biológico funciona como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) que gera uma entrada efetiva.

As entradas x_i que chegam através dos dendritos e os pesos (atribuído pela sinapse) w_i são combinados usando função não linearidade (NL), para produzir um estado de ativação do neurônio (corresponde à frequência de descarga do neurônio biológico).

Figura 37 – Neurônio artificial



Fonte: Lopes (2005).

A Figura 37 mostra o modelo de um neurônio, que forma a base para o projeto de redes neurais, no qual podem-se destacar três elementos básicos do modelo neural (HAYKIN, 2008):

- Um conjunto de sinapses, caracterizadas pelos seus pesos de conexão, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} , sendo

que o primeiro índice (k) se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse a qual o peso se refere (HAYKIN, 2008);

- Bloco Somatório, que soma todos os sinais de entrada ponderados pelos pesos das respectivas conexões (HAYKIN, 2008);
- Função de ativação para restringir a amplitude da saída do neurônio, limitando o intervalo permitido de amplitude do sinal de saída a um valor finito (HAYKIN, 2008);

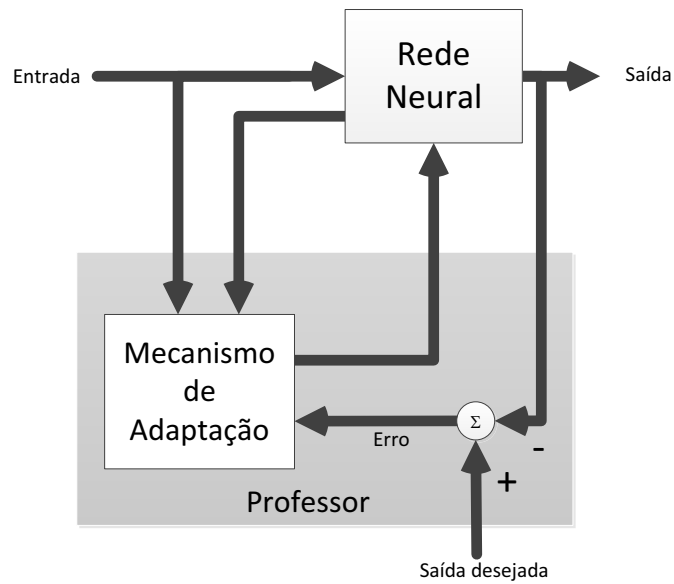
APRENDIZADO E TREINAMENTO

Aprendizado acontece quando a rede neural alcança uma solução generalizada para um mesmo tipo de problemas. Habilidade de aprender de seu ambiente e melhorar seu desempenho é a característica mais importante de uma rede neural.

O aprendizado em uma RNA é decorrente do treinamento da rede através da atribuição de pesos sinápticos com valores apropriados, onde o treinamento se torna completo no momento em que é aplicado um conjunto de entradas, sequencialmente. Os pesos da rede se ajustam de acordo com o procedimento predeterminado. Os pesos da rede convergem gradualmente a determinados valores, à medida que o vetor de entrada produz o vetor de saída desejado (WASSERMAN, 1989).


Esse ajuste dos pesos, obtidos pelo treinamento da rede, pode ser feito das seguintes formas:

Treinamento supervisionado: a rede é treinada pela apresentação dos vetores de entrada e seus respectivos vetores de saída. Esse treinamento exige a presença de um agente externo (professor) na fase de aprendizado, que avalia e informa a rede seu desempenho, conforme pode ser observado na Figura 38. Exemplos de redes que utilizam esse treinamento: Madaline (algoritmo de aprendizagem backpropagation) (WIDROW; HOFF, 1960) e ARTMAP (convencional e fuzzy) (CARPENTER; GROSSBERG; REYNOLDS, 1991, CARPENTER; GROSSBERG, 1992).

Figura 38 – Treinamento supervisionado

Fonte: Haykin (2008).

Treinamento não-supervisionado: o treinamento utiliza apenas os vetores de entrada, a partir dos quais são extraídas as características desse conjunto de padrões, agrupando em classes. A rede é autônoma (Figura 39), onde o sistema é suposto como sendo capaz de descobrir, estatisticamente, características relevantes dos dados de entrada. Como exemplos que utilizam esse treinamento pode se citar: Hopfield (HOPFIELD, 1982), Kohonen (KOHONEN, 1972) e ART (Convencional e Fuzzy) (CARPENTER; GROSSBERG; 1987a, CARPENTER; GROSSBERG; ROSEN, 1991).

Figura 39 – Treinamento não-supervisionado

Fonte: Haykin (2008).

Para solucionar um problema é utilizado o algoritmo de aprendizado que são o conjunto de regras bem definidas, existem muitos tipos de algoritmos de aprendizados específicos para determinados modelos de redes neurais. Dentre eles destacam-se: regra de

Hebb (HEBB, 1949), regra delta de Widrow e Hoff (WIDROW; HOFF, 1960), regra delta generalizada (RUMMELHART; HINTON; WILLIAMS, 1985) e algoritmo de aprendizagem backpropagation (WERBOS, 1974).


Todo conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos as conexões entre os neurônios.

CLASSIFICAÇÃO DE REDES NEURAIAS ARTIFICIAIS

As redes neurais podem ser classificadas, com relação à propagação dos dados, em dois tipos quanto a sua estrutura: redes recorrentes e redes não-recorrentes (feedforward) (KROSE; SMAGT, 1996).


Redes neurais recorrentes: contem laços de realimentação (feedback), ou seja, contem conexões de saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. Desenvolvem uma memória a longo prazo nos neurônios internos (Figura 40). Como exemplos desse tipo de rede pode-se citar a rede de Hopfield (HOPFIELD, 1982).

Figura 40 – Rede neural não-recorrente



Fonte: Haykin (2008).

Redes neurais não-recorrentes: rede disposta em camadas, onde cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação (Figura 41). O processamento pode se estender sobre múltiplas camadas.

Figura 41 – Treinamento não-supervisionado

Fonte: Haykin (2008).

APÊNDICE C

LÓGICA FUZZY

A lógica fuzzy, também conhecida como lógica difusa ou lógica nebulosa, tem como base a Teoria dos Conjuntos Fuzzy, introduzida por Zadeh em 1965 (ZADEH, 1965), para tratar e representar as incertezas.

Enquanto a lógica tradicional trata problemas assumindo duas possibilidades ou estados (verdadeiro ou falso), a lógica Fuzzy pode descrever um determinado fato com detalhes, aproximando-se do mundo real onde não existem somente essas duas possibilidades.

Segundo Cox (COX, 1994), a lógica Fuzzy permite que seja possível mensurar o grau de aproximação da solução exata e assim inferir valores intermediários de graus de verdade.

As variáveis Fuzzy são adjetivos que modificam a variável, de tal forma que noções como bastante morno ou bastante frio sejam formulados matematicamente e processadas por um computador (BAUER; NOUAK; WINKLER, 1996).

CONJUNTOS FUZZY

A teoria dos Conjuntos Fuzzy aborda funções que mapeiam valores no intervalo entre 0 e 1, ou seja, indica o grau de pertinência desse elemento em relação ao conjunto. Esse grau de pertinência verifica o quanto “é possível” esse elemento pode pertencer ao conjunto, ou seja, verifica se um determinado elemento pertence a um domínio.


O grau de pertinência é calculado através de uma função, a qual retorna valor real que alterna entre 0 e 1, sendo que 0 mostra que não pertence ao conjunto e 1 que pertence ao conjunto. Um Conjunto Fuzzy denominado conjunto A deve ser descrito em pares ordenados, onde o primeiro termo do par é o próprio elemento do conjunto (x) e o segundo termo é um número entre 0 e 1, que representa o grau de pertinência ($\mu(x)$) deste elemento em relação ao conjunto A (BAUER; NOUAK; WINKLER, 1996). Esse grau de pertinência é binário, ou seja, pertence ou não pertence ao conjunto.

OPERADORES FUZZY

Da mesma forma que os conjuntos clássicos, nos Conjuntos Fuzzy também existem as operações básicas que combinam e modificam conjuntos. Os operadores básicos dos conjuntos Fuzzy são: intersecção, união e complemento (ZADEH, 1965).

Para exemplificar o funcionamento dos operadores com suas respectivas funções de pertinência considere os dois conjuntos nebulosos μ_A e μ_B , conforme pode ser observado na Figura 42.


Figura 42 – Conjuntos nebulosos



Fonte: Bauer, Nouak e Winkler (1996).

Operador Intersecção (AND): usa a função de pertinência mínimo ($A \cap B$) de dois conjuntos Fuzzy, definida por: $\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x)$, onde $\forall x \in X$. Na Figura 43, a linha azul ilustra a intersecção dos dois conjuntos nebulosos A e B (BAUER; NOUAK; WINKLER, 1996).


Figura 43 – Operador AND



Fonte: Bauer, Nouak e Winkler (1996).

Operador União (OR): usa a função de pertinência máximo ($A \cup B$) de dois conjuntos Fuzzy definida por: $\mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x)$, sendo $\forall x \in X$. Na Figura 44, a linha azul ilustra a união dos dois conjuntos nebulosos A e B (BAUER; NOUAK; WINKLER, 1996).


Figura 44 – Operador OR



Fonte: Bauer, Nouak e Winkler (1996).

Operador Complemento (NOT): usa a função de pertinência complemento ($\sim A$) de um conjunto Fuzzy, definida por: $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$, onde $\forall x \in X$. Na Figura 45, a linha azul mostra o complemento do conjunto nebuloso A (BAUER; NOUAK; WINKLER, 1996).

Figura 45 – Operador NOT




Fonte: Bauer, Nouak e Winkler (1996).

SISTEMAS DE CONTROLE FUZZY

Os sistemas de Controle Fuzzy são compostos de um controlador Fuzzy, um interpretador de entradas e um interpretador de saídas (Figura 46). O controlador Fuzzy é composto pelas funções de pertinência e pelas regras fuzzy, as quais consistem em implicações lógicas formuladas com o uso de variáveis e termos linguísticos (COX, 1994).

Figura 46 – Sistema de Controle Fuzzy



Fonte: da própria autora.

Essas implicações contêm as informações que permitem relacionar as condições de entrada do sistema de controle às saídas geradas por ele. As regras Fuzzy podem ser extraídas de dados numéricos ou fornecidas por especialistas. As regras são formuladas usando a declaração if-then (**Se** condições **então** ação). As condições são obtidas através das entradas dos conjuntos nebulosos e a consequência é a emissão de saídas dos conjuntos nebulosos que representam ações de controle.

Fuzzificação é o processo que armazena todos os valores do universo que está sendo modelado, de cada variável, em um vetor de pertinência ou através de consultas a tabelas de valores discretos de entrada e valores de pertinência correspondentes. Cada elemento do vetor representa o grau de pertinência do valor medido em relação a cada conjunto Fuzzy representante de cada termo linguístico (SIMÕES; SHAW, 2007). Por exemplo: variável altura, os graus de pertinência são os conjuntos alto, médio e baixo.

Após o processamento dos dados e das regras, o controlador fuzzy obtém um valor que representa também um vetor de pertinência, referente à variável de saída, ou seja, a saída apresenta um resultado fuzzy. Porém, há casos em que é necessário obter o valor da saída correspondente no universo de discurso. O processo que permite ao controlador esta transformação é denominado Defuzzificação.


Defuzzificação é a etapa em que os valores fuzzy são convertidos em números reais tendo assim um conjunto de saída matematicamente definido (COX, 1994).

APÊNDICE D

SUBESTAÇÕES

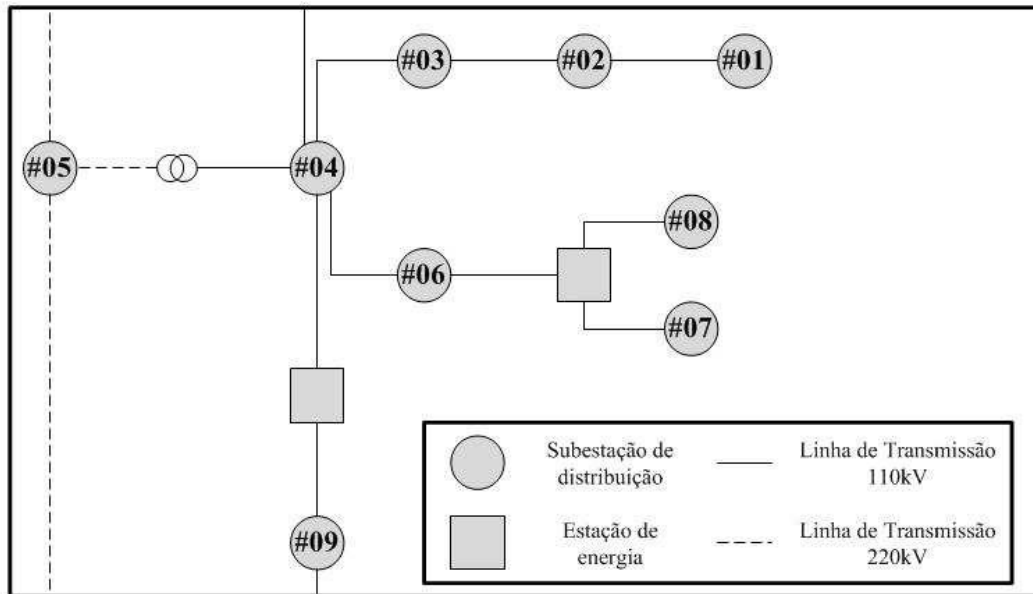
Neste apêndice são apresentadas as informações sobre a localização geográfica do sistema sob estudo (nove subestações de uma empresa do setor elétrico da Nova Zelândia) e o diagrama elétrico, respectivamente as Figuras 47 e 48. Trata-se de dados extraídos do Centralised Dataset (CDS) fornecidos pela Electricity Commission da Nova Zelândia (www.electricitycomission.govt.nz). As especificações dos transformadores das nove subestações e detalhes de cada região da subestação conforme mostrado na Tabela 4.

Figura 47 – Localização geográfica das subestações



Fonte: Nose-Filho (2010).

Figura 48 – Diagrama elétrico



Fonte: Nose-Filho (2010).

Tabela 4 – Especificações dos transformadores de cada subestação

Subestação	Tensão (kV)	Potência (MVA)	Detalhes da Região
# 01 Kopu	2x110/66	2 x 45	Região rural com pequeno vilarejo.
# 02 Waikino	2x110/33	2 x 30	Pequena cidade.
# 03 Waihou	3x110/33	3 x 20	Região rural.
# 04 Hamilton 1	2x110/11	2 x 40	Cidade de médio porte com aproximadamente 185.000 habitantes, sendo a quarta maior área urbana e a sétima maior cidade do país.
# 05 Hamilton 2	2x220/33	2 x 100	
# 06 Cambridge	2x110/11	2 x 38	Pequena cidade com aproximadamente 16.000 habitantes.
# 07 Te Awamutu	2x110/11	2 x 40	Pequena cidade com cerca de 10000 habitantes rodeada por uma extensa região rural, totalizando 14000 habitantes aproximadamente.
# 08 Hinuera	2x110/33	1 x 30 + 1x 50	Pequeno vilarejo.
# 09 Kinleith	2x110/33	1 x 30	Região caracterizada pelo processamento de madeira e produção de papel.

Fonte: Nose-Filho (2010).

APÊNDICE e

ESTUDO E MODELAGEM DA BASE DE DADOS

Em Nose-Filho (2010) foi feito um estudo da carga total das 9 subestações da região de Hamilton – Nova Zelândia. Este estudo é apresentado de forma detalhada nesse apêndice.

Foram disponibilizados os valores de carga de 9 subestações da referida região, referente aos anos de 2007, 2008 e de janeiro a março de 2009 inclusive. Estes dados foram extraídos do Centralised Dataset (CDS) fornecidos pela Electricity Commission da Nova Zelândia (www.electricitycomission.govt.nz).

Os dados históricos incluem várias informações a respeito da carga, entre elas as principais são:

- os valores de cargas, medidos de meia em meia hora (48 amostras por dia) em kW;
- data (dia, mês e ano de referência);
- amostra correspondente à carga [1:48];
- o tipo de dia (o dia da semana ou o feriado correspondente);
- se é pertencente ao horário de verão ou não.

Além disso, foi possível obter o valor das temperaturas máximas e mínimas diárias, observadas de uma subestação meteorológica que distancia não mais de 100km de cada uma das 9 subestações de energia elétrica. Estes dados foram obtidos do sistema CliFlo que dá acesso web ao National Climate Database da Nova Zelândia.

Através destes dados, foi possível realizar vários estudos referentes à carga total das 9 subestações, denominada aqui de carga global do sistema. Por causa do horário de verão, cada ano apresenta um dia com 23 e outro com 25 horas. Antes de iniciar os estudos, foi incluída uma hora no dia com 23 horas e excluída uma hora do dia com 25 horas, deixando assim todos os dias com 24 horas.

Estes estudos sugerem a estimação de informações relevantes para a entrada de dados das redes neurais artificiais que realizam as previsões. Em muitos casos, este estudo é totalmente dispensado, tendo em vista que a rede é capaz de “aprender” o comportamento da

carga. Porém, neste caso, pretende-se obter uma melhoria na precisão e na confiabilidade dos dados, inserindo parâmetros refinados e com ligação direta e indireta nos valores das cargas.

Os estudos são baseados nas cargas globais dos anos de 2007 e 2008, tendo em vista que se pretende realizar previsões para o ano de 2009.

Através dos dados dos anos de 2007 e 2008, foi possível realizar seis estudos. Cinco deles foi constatada a influência dos fatores externos sobre a carga e um deles verificou a influência da carga passada sobre a carga.

A partir dos estudos que foram realizados com as cargas, são realizados-se os seguintes estudos:


- O comportamento da carga global durante os anos de 2007 e 2008;
- O comportamento da carga média de uma semana dos anos de 2007 e 2008;
- A análise do efeito do horário de verão;
- A análise de feriados e dias atípicos;
- A análise da periodicidade e frequência da carga;
- A correlação entre os valores da carga que se deseja prever com os valores de cargas passados.

ESTUDO 1 – COMPORTAMENTO DA CARGA GLOBAL

Através desse estudo, observou-se que a variação da carga, durante os meses dos anos de 2007 e 2008, foi muito parecida, sofrendo um aumento no consumo global nos meses de maio até setembro que são os meses com temperaturas mais baixas, correspondentes aos períodos de outono e inverno. Deste modo, para prever os três primeiros meses do ano de 2009, é muito importante inserir, no treinamento, os três primeiros meses de 2007 e 2008, pois as cargas deverão ser muito parecidas, ou pelo menos possuir as mesmas características. Também, pôde-se perceber que não houve crescimento da carga para o ano de 2008. Sendo assim, espera-se para o ano de 2009, pouco ou nenhum crescimento da carga.

Na Figura 49 ilustra-se o comportamento da carga amostrada de meia em meia hora durante os anos de 2007 e 2008. Desse modo, é possível perceber que o mês correspondente a carga é uma informação relevante que deve ser levada em consideração na hora de se realizar a previsão. Com isso, todo mês foi normalizado dividindo por doze, ou seja, mês/12.

Figura 49 - Comportamento da carga global 2007 e 2008




Fonte: Nose-Filho (2010).

ESTUDO 2 – COMPORTAMENTO DA CARGA MÉDIA DE UMA SEMANA

Na Figura 50, observa-se que a curva de carga da segunda-feira possui um comportamento distinto das curvas de cargas da terça, quarta, quinta e sexta-feira. O sábado e o domingo também possuem comportamentos distintos. Portanto, é necessária a diferenciação dos dias das semanas em grupos, onde cada grupo pode ser formado por um dia da semana, ou podem ser formados quatro grupos. Ou seja, um grupo para as segundas-feiras, um grupo para as terças, quartas, quintas e sextas-feiras, um grupo para os sábados e outro grupo para os domingos.

Deste modo, a informação do dia da semana é um parâmetro relevante para a composição do padrão de entrada. Esta informação será composta por 4 elementos binários os quais serão ativados da seguinte maneira: 1 0 0 0 para a segunda-feira, 0 1 0 0 para os demais dias da semana (terça à sexta-feira), 0 0 1 0 para sábados e 0 0 0 1 para domingos.

Figura 50 - Curva de carga média de cada dia da semana (2007 e 2008)




Fonte: Nose-Filho (2010).

ESTUDO 3 – ANÁLISE DO EFEITO DO HORÁRIO DE VERÃO

Na Figura 51 observa-se que o horário de verão exerce influência na curva de carga, reduzindo seus valores de pico, começando na segunda-feira até o domingo dos anos de 2007 e 2008. Portanto, é necessário diferenciar as cargas que estão sob o horário de verão das cargas das demais estações.

Deste modo, a informação de que um dia pertence ou não ao horário de verão é relevante na previsão de carga e será um elemento de entrada binário, sendo 1 para os dias pertencentes ao horário de verão e 0 para os dias não pertencentes ao horário de verão.

Figura 51 - Curva média de cada dia da semana pertencente e não pertencente ao horário de verão




Fonte: Nose-Filho (2010).

ESTUDO 4 – ANÁLISE DE FERIADOS E DIAS ATÍPICOS

Geralmente, feriados e dias atípicos são caracterizados por um consumo anormal de carga que, na grande maioria, é inferior ao consumo de um dia convencional. Este comportamento pode ser observado na Figura 52. Neste caso, é necessário diferenciar as cargas dos dias convencionais com as cargas dos dias atípicos e feriados. As curvas em azul correspondem aos dias convencionais e as curvas em vermelho correspondem aos feriados e dias atípicos.

Como se pode observar, os dias atípicos possuem curvas de cargas abaixo dos patamares de cargas de dias normais. Com isso pode-se concluir que o consumo nestes dias está abaixo do esperado para um dia convencional. Deste modo, esta informação é relevante para que a previsão não seja superestimada. Esta informação será representada de forma binária à rede, ou seja, 1 representando um dia atípico e 0 representando um dia convencional.

Figura 52 - Curvas de cargas dos dias da semana dos anos de 2007 e 2008




Fonte: Nose-Filho (2010).

ESTUDO 5 – ANÁLISE DE PERIODICIDADE E FREQUÊNCIA DAS CARGAS

Para verificar a periodicidade e frequência das cargas, foi realizado esse estudo, Figura 53, onde se realizou a análise espectral das cargas dos anos de 2007 e 2008. Verificou-se que a carga possui uma periodicidade de 24 e 48 amostras, sendo que a fundamental pertence à frequência com período de 48 amostras.

Deste modo, foi modelado um parâmetro de entrada composto de um sinal período de período igual a 48 amostras, cuja entrada é o número da amostra que se deseja realizar a previsão e a saída é um sinal composto por estes dois componentes.

Figura 53 - Análise espectral das curvas de carga dos anos de 2007 e 2008



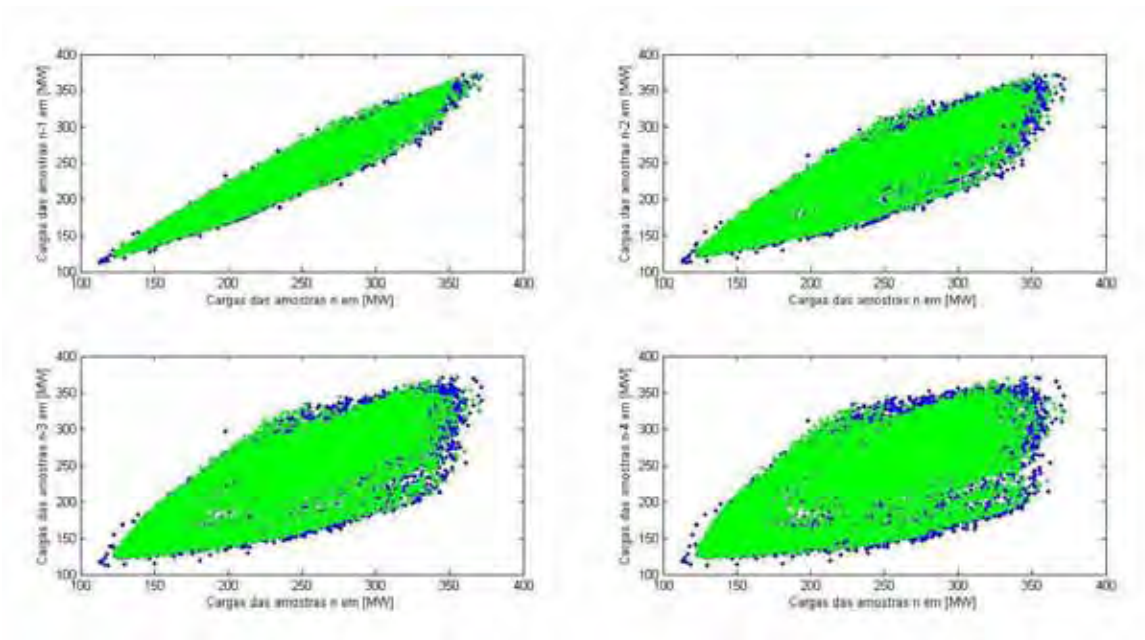
Fonte: Nose-Filho (2010).

ESTUDO 6 – CORRELAÇÃO DAS PASSADAS COM AS FUTURAS

O estudo serviu para analisar a relação que a carga da amostra n tem com as demais cargas passadas. Neste caso, observou-se que a carga da amostra n possui uma forte relação com a carga da amostra $n-1$. Esta relação se enfraquece com as demais cargas passadas (Figura 54).

Deste modo, é possível observar que a curva das cargas das amostras n pelas cargas das amostras $n-1$ possuem uma forte relação linear, sendo esta a única escolhida para compor a janela de carga.

Figura 54 - Correlação das cargas das amostras n com a amostras n-1, n-2, n-3 e n-4



Fonte: Nose-Filho (2010).